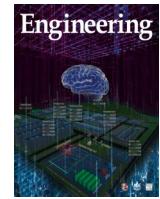




ELSEVIER

Contents lists available at ScienceDirect

Engineering

journal homepage: www.elsevier.com/locate/eng

Research

Active Support of Power System to Energy Transition——Article

基于深度学习技术的集群电动汽车及家庭热水系统灵活性预测

胡俊杰^{a,*}, 周华嫣然^a, 周羿宏^a, 张海婧^a, Lars Nordströmd^b, 杨光亚^c^a State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Beijing 102206, China^b Division of Electric Power and Energy Systems, School of Electrical Engineering and Computer Science, KTH Royal Institute of Technology, Stockholm 10044, Sweden^c Center for Electric Power and Energy Department of Electrical Engineering, Technical University of Denmark, Kgs Lyngby 2800, Denmark

ARTICLE INFO

Article history:

Received 8 October 2020

Revised 16 January 2021

Accepted 29 March 2021

Available online 24 June 2021

关键词

负荷灵活性

电动汽车

家庭热水系统

结合时间卷积神经网络的 Transformer 模型

深度学习

摘要

随着电网中间歇性可再生能源发电规模的增大,为了保证电能质量和频率的稳定性,电网对可控资源的需求也随之增加。需求响应(demand response, DR)资源的灵活性已成为解决这一问题的一个有价值的方法。然而,目前关于DR资源的灵活性预测问题尚未得到充分的研究。本研究应用一种深度学习技术,即结合时间卷积神经网络的Transformer模型(temporal convolution network-combined transformer)来预测电动汽车与家庭热水系统两种DR资源的聚合灵活性。所提出的灵活性预测方法使用了基于DR资源的历史用电数据以及为了辅助预测所提出的DR信号数据。所提方法不仅可以预测聚合灵活性的大小,还可以预测其维持时间。最后,本文通过算例仿真验证了灵活性预测结果的准确性。仿真结果表明,在不同的灵活性维持时间下,DR资源灵活性的大小会发生变化。文中所提出的DR资源灵活性预测方法展现了其在释放需求侧资源的灵活性以向电网提供备用容量方面的应用。

© 2021 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. 引言

近几十年来,对环境问题的关注在很大程度上促进了可再生能源的使用[1]。由于可再生能源发电和分布式能源的内在不确定性,这种转变将会给电力系统的运行带来挑战。其中,主要的挑战是电力供需之间的不平衡日益加剧,这将导致系统中对可控资源的部署需求不断增加,而对传统辅助型服务资源的需求则不断减少[2]。此外,中低压水平下连接的分布式能源数量的增加可能会导致拥塞问题[3]。

随着智能电网和电力市场的发展,需求响应(DR)

资源将成为系统运行不可或缺的一部分。因此,整合DR资源的灵活性成为了保留辅助型服务资源供应的一种有前景的解决方案[4]。请注意,根据国际能源署(IEA)的定义,电力系统的灵活性是指在大干扰期间通过调整发电量或系统负荷来维持系统可靠性的能力[5]。因此,本研究将灵活性定义为DR资源增加和减少电力需求的能力。聚合商可以通过价格补偿或者经济激励来发挥DR资源的灵活性,这将使得DR资源可以根据系统运行的需要调整自身的用电行为[6-7]。然后,聚合商可以在辅助服务市场中交易DR资源的灵活性,为电力系统运行提供可控资源。

* Corresponding author.

E-mail address: junjiehu@ncepu.edu.cn (J. Hu).

到目前为止，关于如何充分利用DR资源的灵活性为电网提供辅助服务，科研人员已经开展了许多研究。为了实现峰值负荷转移效应，Li等[8]建立了电动汽车（EV）集群参与基于价格的DR的模型。Sanandaji等[9]利用住宅供暖、通风和空调（HVAC）总负荷的电力消耗灵活性，以一定的爬坡速率对备用服务进行调控。Hu等[10]在研究中提出了利用DR资源实现多区域电力系统供需平衡的想法。参考文献[11]中提出的方法为提供灵活性的DR参与者建立了奖励机制，并使用DR资源的灵活性来实现供电馈线的负荷转移和电压改进。

如参考文献[8-11]所示，分布式能源聚合的灵活性决定了DR项目的实施效果[12]。然而，考虑到终端用户行为的随机性和DR资源的复杂物理特性，在DR项目落地实施前，DR资源的聚合灵活性通常是不确定的。因此DR项目中广泛采用了数种风险控制策略来处理这种DR资源灵活性的不确定性。参考文献[13]将条件风险价值引入EV模型，从而在辅助服务市场中提供储备，以应对EV模型中灵活性的不确定性。参考文献[14]为EV集群模型中的最优调度建立了鲁棒优化问题，以获得保守的频率调节市场参与策略。针对DR项目中并网EV的实际及预期灵活性之间的偏差，参考文献[15]依靠一种基于预测控制的滚动时域法建立了一个优化模型。Han等[16]使用基于多场景的随机规划方法来处理DR项目中EV模型灵活性的不确定性。虽然参考文献[13-16]中使用的风险控制方法可以帮助聚合商衡量目前DR项目中的不确定性，但其结果可能是高度保守的，这可能导致DR用户的经济利益损失，甚至妨碍DR资源在电网运营中充分展现其灵活性。

一个准确的聚合灵活性预测模型对于其处理参与电网运营时的不确定性至关重要。然而，关于灵活性预测问题的研究很少。许多研究主要集中在电力负荷的预测上，而非直接预测灵活性。Wang等[17]和Chen等[18]提出了一种用于系统规划和调度的概率负荷预测方法。参考文献[19]中，作者回顾了当前的能量预测方法并提供了未来的研究方向。然而，他们没有讨论对于灵活性的直接表示与预测方法。目前，关于灵活性的研究仍大多停滞于定义和评价阶段。参考文献[20]提供了EV灵活性的表示方法，考虑了EV对于频率调节的参与情况，并使用三年的数据评估了EV在频率调节中的灵活性。对于住宅DR负荷问题，在参考文献[21]中，作者建立了需求变化的二项概率分布模型，并使用最大似然估计来评估需求增加、需求减少或需求固定时的灵活性。

在参考文献[22]中，作者提出了一种基于循环神经网

络（RNN）的灵活性预测方法，以获取聚合的家用生活热水系统（DHWS）的灵活性。利用DHWS的灵活性预测结果，可以在一定精度下解决日前实时的负荷转移调度问题。然而，该研究所提出的基于RNN的灵活性预测方法只能预测聚合灵活性的尺度，而不能呈现灵活性的维持时间。此外，普通的基于RNN的方法可能在复杂问题中表现不佳。例如，当输入序列足够长时，RNN可能会出现梯度爆炸或者梯度消失的问题，因此该方法的适用性存在缺陷[23-24]。

在文献[22]提出的基于RNN的灵活性预测的基础上，本研究采用了一种先进的深度学习网络，即结合时间卷积网络（TCN）的Transformer模型，实现了对两种典型DR资源——EV和DHWS的实时聚合灵活性的多步超前预测。该方法考虑了物理特性以及不同的功耗策略。本研究的主要贡献有两个方面。首先，本研究为DR资源提供了一种通用的提前多步的灵活性预测方法。通过本研究所提出的灵活性预测方法，可以得到聚合灵活性的尺度及持续时间。其次，我们使用结合TCN的Transformer模型来解决聚合EV和DHWS的灵活性预测。结合TCN的Transformer预测模型是用于建模长时间依赖问题最先进的模型之一。经过实例模拟研究，具有长预测时隙的灵活性预测的准确性得以验证。本研究所提出的灵活性预测方法可以支持DR规划和运行问题，如向电网提供备用容量服务等。

本文的其余部分组织如下：第2节为研究提供了准备工作，内容包括问题描述、系统框架以及一些重要定义；第3节详细描述了基于结合TCN的Transformer的预测方法；第4节介绍了实例仿真模拟研究的结果和讨论；第5节给出结论。

2. 准备工作

2.1. DR资源灵活性的定义

从广义上讲，灵活性是指系统对内部及外部不确定性的响应能力，即系统在内部或外部变量发生变化时的响应能力[25]。然而，在电力系统中，灵活性尚没有统一的定义。目前，一个被广泛接受的定义来自于国际能源署。它将电力系统灵活性定义为在系统遭受大干扰期间通过调整发电机发电量或负荷用电量来维持可靠性的能力[5]。根据国际能源署对灵活性的定义，对于负荷侧的DR资源而言，其灵活性反映在增加或减少电力需求的能力上。

图1说明了DR资源的灵活性。就DR资源的基本功率需求(P_{base})，即正常使用的功耗而言，功率需求可以增

加到 P_{\max} 或减少到 P_{\min} ，其中 $P_{\min} < 0$ 表示DR资源可以向电网供电。 P_{\max} 和 P_{\min} 的值受限于DR资源的物理特性以及用户的要求，本问题将在2.3节中详细讨论。 P_{base} 和 P_{\min}/P_{\max} 之间的距离是减少或增加电力需求的能力，即灵活性。

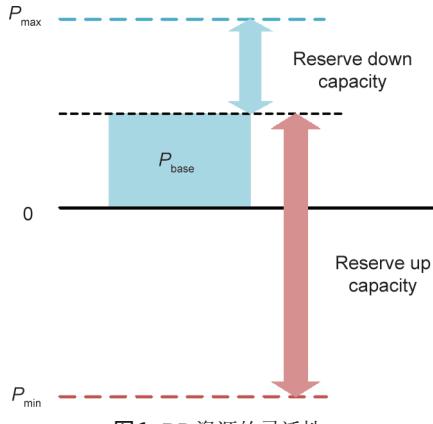


图1. DR资源的灵活性。

这种灵活性可用作电力系统的备用容量。在传统意义上，备用容量为当负荷超出预期时的额外发电能力[16]。备用容量设置可保护电力系统免受未来运行事件（包括能量损失或负荷预测错误）的不确定性的影响。当此类运行事件发生时，DR资源还可以通过增加或减少其电力需求来弥补供需之间的不平衡。因此，可以将DR减少/增加电力需求的能力称为上行/下行备用容量，如图1所示。

DR资源提供备用容量的合理方式是允许它们不对称地申报上行/下行备用容量的值。然而，能量和功率的不确定性和耦合性使得DR灵活性的描述成为一个复杂的问题。为了更好地在电力系统中利用DR资源的灵活性，我们需要探索灵活性的预测方法。

2.2. 问题表述与DR系统框架

我们研究的主要目的是通过使用历史终端用户行为数据库处理实际用电量的数据记录，从而提前多步预测两种典型DR资源（即EV和DHWS）的灵活性。

在预测中，我们研究了聚合形DR的灵活性，因为它可以抵消内部分布式DR资源的不确定性，并且现有的电力市场规则不允许单个客户参与。考虑到EV和DHWS的不同电力消耗特性，分别使用EV聚合商（EVA）和DHWS聚合商（DHWSA）聚合各个EV与DHWS。

$$\begin{cases} F_{\text{EVA}}(t) = \hat{P}_{\text{EVA}}(t) - P_{\text{EVA}}(t) \\ F_{\text{DHWSA}}(t) = \hat{P}_{\text{DHWSA}}(t) - P_{\text{DHWSA}}(t) \end{cases} \quad (1)$$

EVA和DHWSA在时间步长 t 下的灵活性分别表示为

$F_{\text{EVA}}(t)$ 和 $F_{\text{DHWSA}}(t)$ ，可从式(1)中导出。 $P_{\text{EVA}}(t)$ 和 $P_{\text{DHWSA}}(t)$ 分别表示EVA和DHWSA在时间步长 t 下的基本功率需求，这相当于第2.1节中的 P_{base} 。 $\hat{P}_{\text{EVA}}(t)$ 和 $\hat{P}_{\text{DHWSA}}(t)$ 分别代表EVA和DHWSA在参与DR项目时在时间步长 t 下的总功率，相关内容将在下一节中进一步详细讨论。

图2显示了DR系统框架。注意，我们把从电网到需求侧的功率方向定义为正向。EVA和DHWSA可以参与电力能源市场和辅助服务市场进行系统备用容量的竞价。为了更好地对灵活性实现预测及应用，EVA和DHWSA可以通过发送DR信号（DS，见第2.4节中的详细讨论）作为指令，分别协调和调度所有分布式EV和DHWS的功率。当它们根据DS指令改变用电行为时，EVA和DHWSA可以为DR用户提供有吸引力的电费折扣。为了进行分布式EV和DHWS的灵活性预测，EVA和DHWSA都将使用结合TCN的Transformer的技术。结合TCN的Transformer模型将在本文第3节中详细描述。

2.3. EV和DHWS的基本电力需求

如2.1节所述，聚合DR资源的灵活性与基础电力需求密切相关，聚合DR资源的基础电力需求受DR资源的物理特性和终端用户用电策略的影响。

2.3.1. 各个DR资源的物理特性

我们的研究考虑了每辆EV的三种运行模式，即以额定快充功率 P_{fast} 快充、以额定慢充功率 P_{slow} 慢充和额定放电功率 P_{dis} 放电。我们制定了以下约束来表示单个EV的特征，如式(2)~(8)所示：

$$P_{\text{dis}} \leq P_{\text{EV}}(t) \leq P_{\text{fast}}, \quad (2)$$

$$E(t+1) = E(t) + \eta P_{\text{EV}}(t) \Delta t, \text{ if } t \in [t_{\text{start}}, t_{\text{dep}}], \quad (3)$$

$$E(t) = 0, \text{ if } t \notin [t_{\text{start}}, t_{\text{dep}}], \quad (4)$$

$$E(t) = E_{\text{start}}, \text{ if } t = t_{\text{start}}, \quad (5)$$

$$E(t) \geq E_{\text{esp}}, \text{ if } t = t_{\text{dep}}, \quad (6)$$

$$E(t) \leq E_{\text{max}}, \quad (7)$$

$$P_{\text{EV}}(t) \geq P_{\text{slow}}, \text{ if } E(t) < E_{\text{ms}}, \quad (8)$$

式中， $P_{\text{EV}}(t)$ 表示EV在时刻 t 的功率。 $P_{\text{EVA}}(t) = \sum_{\text{EV} \in \text{EVA}} P_{\text{EVA}}(t)$ 表示 $P_{\text{EV}}(t)$ 与 $P_{\text{EVA}}(t)$ 之间的关系。EV在时间步长 t 下的荷电状态（SOC）记为 $E(t)$ 。充电桩（电网）与EV电池之间的能量传递效率记为 η 。我们使用 Δt 来表示采样时间尺度。EV在充电开始时 t_{start} 接电的初始荷电状态可表示为 E_{start} 。断电时 t_{dep} 的预期荷电状态可表示为 E_{exp} 。荷电状态的最大限额可表示为 E_{max} 。EV需充电达到

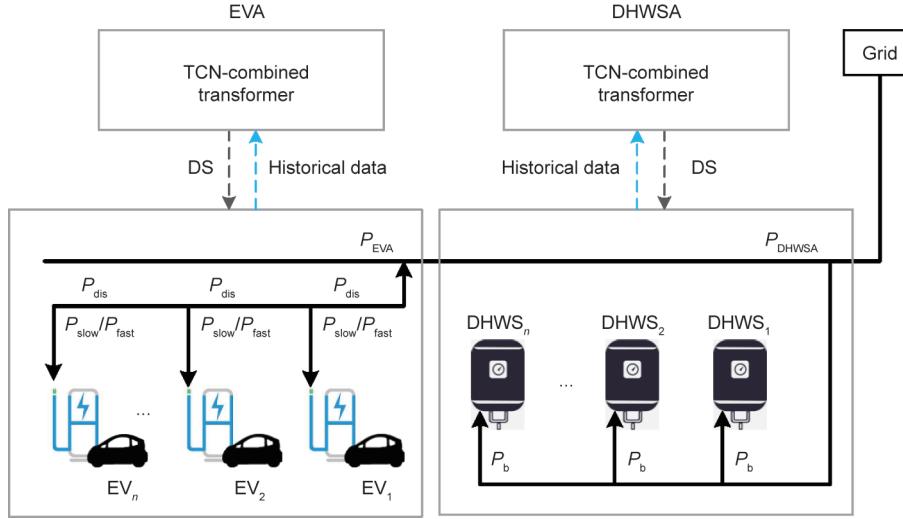


图2. 系统框架。 P_b : DHWS热水器的耗电量; P_{dis} : 以额定放电功率放电; P_{fast} : 以额定快充功率快充; P_{slow} : 以额定慢充功率慢充。

一定荷电状态才能满足驾驶需求,如式(6)所述。 E_{ms} 值可以保证EV的充电需求,这意味着当EV的荷电状态低于 E_{ms} 时,该EV必须处于充电状态。

DHWS用户的需求是将水箱温度 T_{tank} 保持在预设的温度 T_{ref} 附近,允许的最大偏差在固定区间 T_{db} 内,如式(9)中所述。DHWS中热水器的耗电量在本研究中用 P_b 表示,其运行模型公式如下:

$$T_{ref} - T_{db} \leq T_{tank}(t) \leq T_{ref} + T_{db}, \quad (9)$$

$$T_{tank}(t+1) = T_{tank}(t) + \frac{Q_{heat}(t) - Q_{drain}(t) - Q_{loss}(t)}{C_p V_{tank}}, \quad (10)$$

$$Q_{heat}(t) = P_b \Delta t, \quad (11)$$

$$0 \leq P_{DHW}(t) \leq P_b, \quad (12)$$

$$Q_{drain}(t) = V_{flow}(t) C_p (T_{outlet} - T_{inlet}), \quad (13)$$

$$Q_{loss}(t) = A_{tank}(T_{tank}(t) - T_{amb}(t)), \quad (14)$$

式中, $T_{tank}(t)$ 表示时刻 t 时DHWS中水箱的温度。DHWS通过控制恒温式热水器发出的热量 $Q_{heat}(t)$ 将 $T_{tank}(t)$ 保持在预设值 T_{ref} 附近。 $Q_{drain}(t)$ 和 $Q_{loss}(t)$ 分别表示在时刻 t 时,在热水使用过程中,由于终端用户使用而产生的热损失和保温水箱到周围环境的热损失。 C_p 和 V_{tank} 分别是水的比热容和水箱的容积。 P_b 指DHWS中热水器的耗电量, Δt 代表采样时间尺度。DHWS在时间步长 t 下的功率可以表示为 $P_{DHW}(t)$,而 $P_{DHW}(t) = \sum_{DHWS \in DHWSA} P_{DHW}(t) \cdot T_{inlet}$ 和 T_{outlet} 分别是进水与出水的温度。 $V_{flow}(t)$ 表示供应居民当前DHWS运行的热水总流量。 A_{tank} 为水箱的保温系数, $T_{amb}(t)$ 是时刻 t 下的环境空气温度。

2.3.2. DR资源的功耗策略

除了DR资源本身的特性外,用户偏好的用电策略对

基础用电需求也有显著影响。在本研究中,我们将考虑两种典型的用电策略并研究其对灵活性的影响:策略1是最原始的用电方式,即用电方式完全取决于用户的用电需求;策略2是最经济的用电方式,采用该种策略的用户会充分考虑电价,在电价低时往往消耗更多的电量。在未执行分时电价(ToU)的时期,DR用户主要采用策略1进行用电,然而,随着分时电价的普遍使用,策略2越来越被DR用户广泛接受。

按照用电策略1, EV一停车就开始充电,只有当水箱温度达到下限时,热水器才会加热。然而,由于分时电价已广泛应用于EV停车场和住宅区,各个EV和DHWS的耗电量可能受分时电价的影响。因此,在策略2中,我们考虑了分时电价计费规则下的优化功耗模式。策略2中聚合EV和DHWS的优化目标如式(15)所示。

$$\begin{cases} \min c_{ToU}(t) \cdot P_{EVA}(t) \cdot \Delta t \\ \min c_{ToU}(t) \cdot P_{DHW}(t) \cdot \Delta t \end{cases} \quad (15)$$

式中, $c_{ToU}(t)$ 表示分时电价。

与策略1相比,策略2下的部分DR的灵活性已在某些时刻激活以响应分时电价。然而,基于策略2,DR资源仍然具有额外的灵活性。如果电网有应急备用容量需求,使用策略2提前预测DR资源灵活性将有助于DR资源为电网提供备用容量。此类型的需求响应过程可以通过额外的补贴来推动。

两种功耗策略都受到各个EV[式(2)~(8)]和DHWS[式(9)~(14)]的物理特性的约束,我们假设EV的快速充电模式只是在参与DR项目时启用。

2.4. 需求响应信号

在本节中,我们使用DS来预测DR灵活性并帮助实

施DR管理。根据DR管理中的说明，DS由EVA或DHW-SA发送到分布式EV或DHWS。DS的不同值代表不同的DR要求，分布式EV和DHWS需要根据它们收到的不同DS值来切换其用电量。我们定义了三个DS值来表示EV和DHWS相应的响应，如表1所示。图3给出的示意图更好地阐明不同DS值下单个EV和DHWS的电力与状态变化。要注意的是，本研究中相同的DS是从EVA或DHW-SA被发送到所有分布式EV和DHWS。

2.5. 基于DS的灵活性公式

由于已经在第2.4节中设置了DS，因此可以推断出，在 $DS = 0$ 的情况下，式(1)中的 $\hat{P}_{EVA}(t)$ 和 $\hat{P}_{DHWSA}(t)$ 分别等于 $P_{EVA}(t)$ 和 $P_{DHWSA}(t)$ 。最终，式(1)可改写为：

$$\begin{cases} F_{EVA}(t) = \hat{P}_{EVA}(t) \Big|_{DS=0} - \hat{P}_{EVA}(t) \Big|_{DS \neq 0} \\ F_{DHWSA}(t) = \hat{P}_{DHWSA}(t) \Big|_{DS=0} - \hat{P}_{DHWSA}(t) \Big|_{DS \neq 0} \end{cases} \quad (16)$$

式中， $\hat{P}_{EVA}(t) \Big|_{DS=0}$ 和 $\hat{P}_{DHWSA}(t) \Big|_{DS=0}$ 分别代表 $DS \neq 0$ 时的聚合EV和DHWS的总功率； $\hat{P}_{EVA}(t) \Big|_{DS=0}$ 和 $\hat{P}_{DHWSA}(t) \Big|_{DS=0}$ 分别表示 $DS = 0$ 时EV和DHWS的总功率。

DR计划通常需要DR资源的灵活性，以提供一个可以维持一段时间的值。因此，本文提出了一种基于DS的灵活性计算方法，以推导出DR资源在不同维持时间下的灵活性。首先，我们应该在 k 时间步长内充分激活所有分布式EV和DHWS的灵活性值。因此，EVA和DHSWA可以向所有分布式EV和DHWS发送 $DS(t)=1, DS(t+1)=1, \dots, DS(t+k)=1$ [或者 $DS(t)=-1, DS(t+1)=-1, \dots, DS(t+k)=-1$]，这意味着增加（或减少）电力消耗至少可保持 k 时间步长。之后，基于DS可推导出灵活性 $F(t), F(t+1), \dots, F(t+k)$ 。基于 $F(t), F(t+1), \dots, F(t+k)$ 的值，在最小 k 时间步长处剩余的灵活性 F^k 可以通过找到 $|F(t)|, |F(t+1)|, \dots, |F(t+k)|$ 的最小值来获得。如式(17)所示，式中的下标表示应用于EVA或者DHW-SA。需注意的是，找到最小值的物理意义是确保灵活性可以在几个连续时间步长内以常数值的块形式呈现。我们可以从式(17)推断，由于DR资源的能量有限，除了基本计划之外，维持时间也是导致灵活性变化的原因。如果电力导致荷电状态达到EV电池容量的边界或DHWS的水箱温度达到参考温度的边界，那么DR资源则无法向或从电网输送电力。因此，灵活性相应地降低。

$|F_{EVA}^k| = \min [|F_{EVA}(t)|, |F_{EVA}(t+1)|, \dots, |F_{EVA}(t+k)|]$

$|F_{DHWSA}^k| = \min [|F_{DHWSA}(t)|, |F_{DHWSA}(t+1)|, \dots, |F_{DHWSA}(t+k)|]$

(17)

因此，基于上述分析和建模方法，我们可以获得聚合EV和DHWS相应的灵活性。为了更直观地解释本文提出的基于DS的灵活性计算过程，图3给出了在不同DS值下持续两个时间步长的单个EV和DHWS的示例。图3所示的灵活性计算结果见表2。

如式(16)中的定义，当 $DS = 1$ 时，图3中示例EV的灵活性为 $P_{fast} - P_{slow}$ ，该灵活性可以保持两个时间步长。当 $DS = -1$ 时，调度灵活性为 $P_{dis} - P_{slow}$ ；然而，考虑EV用户的能源需求，灵活性只能保持一个时间步长。因此，根据式(16)，如果计算两个时间步长下示例EV的灵活性，其结果为0。

对于图3中的示例DHWS，当 $DS = 1$ 时，它可以提供维持时间为两个时间步长的 P_b 调度灵活性。由于水箱温度的限制，当 $DS = -1$ 时，DHWS无法提供任何灵活性。考虑EV和DHWS都具有时间耦合约束，如式(3)和式(10)所示，下一个时间步长的灵活性受前一个时间步长的灵活性所影响。因此，在 $DS = -1$ 时，如果水箱的状态是在加热而不是散热，那么DHWS可以中断加热以提供调度灵活性。

表1 DS值以及单个EV和DHWS的相应反应

DS value	Demand	EV response	DHWS response
1	Reserve down	Increase charging power or decrease discharging power	Increase the power consumption of the boiler
-1	Reserve up	Decrease charging power or increase discharging power	Decrease the power consumption of the boiler
0	Not engage in DR program	No need for state switching	No need for state switching

表2 图3相应的灵活性计算结果

DS value and maintaining time	EV flexibility and maintaining time	DHWS flexibility and maintaining time
$DS = 1, 2$ time steps	$P_{fast} - P_{slow}, 2$ time steps	$P_b, 2$ time steps
$DS = -1, 2$ time steps	0	0

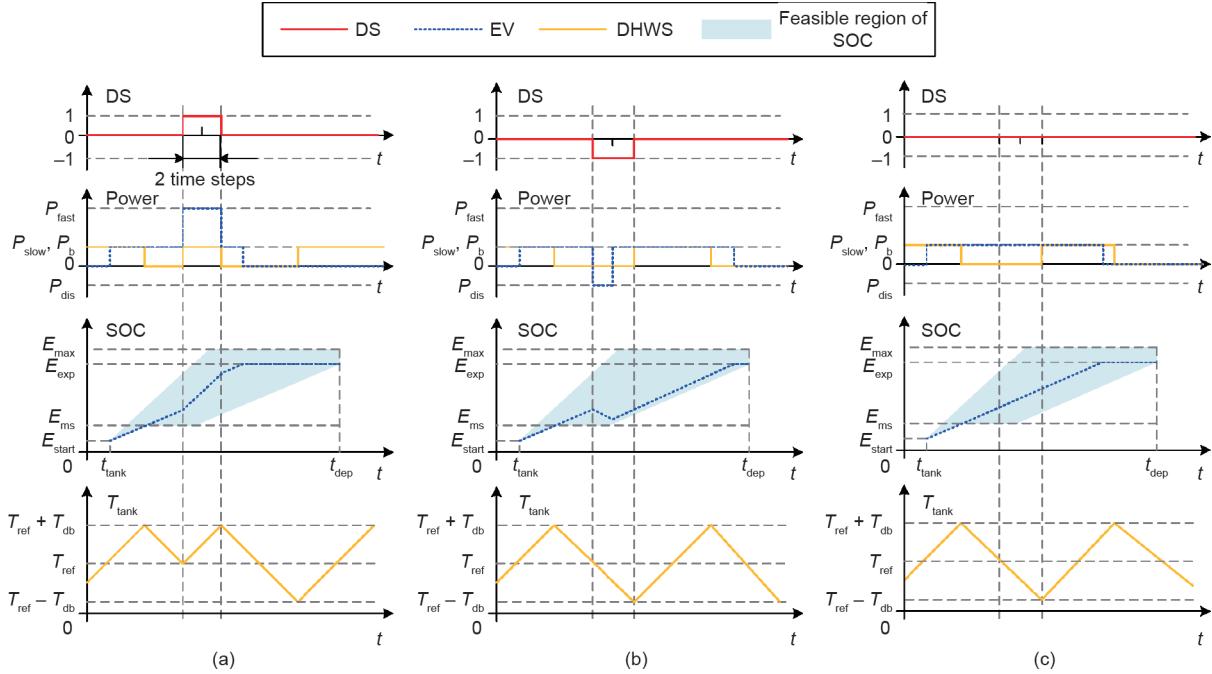


图3. 不同DS值下单个EV和DHWS在两个时间步长下的功耗和状态。(a) DS = 1; (b) DS = -1; (c) DS = 0。

3. 灵活性预测方法和算法

3.1. 序列到序列(基于Seq2Seq)的灵活性预测方法

为了预测EV和DHWS多步超前的灵活性，我们首先在 $DS = 0$ 和 $DS \neq 0$ 的情况下，根据式(16)、(17)预测了 $\hat{P}_{EVA}(t)$ 和 $\hat{P}_{DHWSA}(t)$ 。在这里，我们说明预测的过程。 $P_{EVA}(t)$ 和 $P_{DHWSA}(t)$ 的分析是相似的，因此为简化起见，在第3节后面部分仅对 $P_{EVA}(t)$ 进行分析。

我们将 t 表示为预测槽的第一个时刻，将 $P_{EVA}(t)$ 表示为EVA的基础功率（这在不同的策略中会有所不同）。当第一个DS($DS(t)$)将 $P_{EVA}(t)$ 变为 $\hat{P}_{EVA}(t)$ 时，我们用 $F(\cdot)$ 来表示这个变换，因此得到式(18)。

$$\hat{P}_{EVA}(t) = F[P_{EVA}(t), DS(t), e_{EVA}(t)] \quad (18)$$

在式(18)中， $e_{EVA}(t)$ 表示可能有助于 $\hat{P}_{EVA}(t)$ 的值的其他外部条件，这取决于问题策略。需注意的是，可以将 $P_{EVA}(t)$ 的预测公式表示为参考文献[26–27]中的时间序列预测模型。这也保证EV和DHWS的时间耦合约束。因此，我们得到式(19)。

$$P_{EVA}(t) = f[P_{EVA}(t-1), P_{EVA}(t-2), \dots, P_{EVA}(t-N); u_{EVA}(t), u_{EVA}(t-1), \dots, u_{EVA}(t-N)] \quad (19)$$

同理， $u_{EVA}(t)$ 是可能影响 $P_{EVA}(t)$ 的外部因素， N 代表所考虑的时间依赖的长度。将式(19)代入式(18)，并应用式(20)~(22)中的定义：

$$\text{Encoder}[\dot{P}_{EVA}, \dot{u}_{EVA}] = f[P_{EVA}(t-1), P_{EVA}(t-2), \dots, P_{EVA}(t-N); u_{EVA}(t), u_{EVA}(t-1), \dots, u_{EVA}(t-N)] \quad (20)$$

$$\dot{u}_{EVA} = [u_{EVA}(t), u_{EVA}(t-1), \dots, u_{EVA}(t-N)] \quad (21)$$

$$\dot{P}_{EVA} = [P_{EVA}(t-1), P_{EVA}(t-2), \dots, P_{EVA}(t-N)] \quad (22)$$

我们得到超前一个时间步长的预测，如式(23)所示。

$$\hat{P}_{EVA}(t) = F\{\text{DS}(t), e_{EVA}(t), \text{Encoder}[\dot{P}_{EVA}, \dot{u}_{EVA}]\} \quad (23)$$

考虑到需要预测超前多步的 $\hat{P}_{EVA}(t+k)$ ，我们可以重复使用超前一步预测（采用了多步预测问题的形式）作为下一个输入，如参考文献[26–27]所示。因此，我们得到式(24)。

$$\begin{aligned} \hat{P}_{EVA}(t+k) &= F\{\hat{P}_{EVA}(t+k-1), \dots, \hat{P}_{EVA}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); \\ &\quad e_{EVA}(t+k), \dots, e_{EVA}(t); \\ &\quad \text{Encoder}[\dot{P}_{EVA}, \dot{u}_{EVA}]\} \end{aligned} \quad (24)$$

将 $F(\cdot)$ 表示为Decoder[], 我们最终得到式(25)。

$$\begin{aligned} \hat{P}_{EVA}(t+k) &= \text{Decoder}\{\hat{P}_{EVA}(t+k-1), \dots, \hat{P}_{EVA}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); e_{EVA}(t+k), \dots, \\ &\quad e_{EVA}(t); \text{Encoder}[\dot{P}_{EVA}, \dot{u}_{EVA}]\} \end{aligned} \quad (25)$$

可以将同样的步骤应用于 $\hat{P}_{DHWSA}(t)$ ，因此得到式(26)。

$$\begin{aligned} \hat{P}_{\text{DHWSA}}(t+k) = & \text{Decoder}\{\hat{P}_{\text{DHWSA}}(t+k-1), \dots, \hat{P}_{\text{DHWSA}}(t); \\ & \text{DS}(t+k), \dots, \text{DS}(t); e_{\text{DHWSA}}(t+k), \dots, \\ & e_{\text{DHWSA}}(t); \text{Encoder}[\dot{P}_{\text{DHWSA}}, \dot{u}_{\text{DHWSA}}(t)]\} \end{aligned} \quad (26)$$

这种形式类似于自然语言处理（NLP）领域的Seq2Seq模型形式[28]；因此，我们可以使用在NLP中被称为最先进的Transformer模型来实现这种预测。

3.2. Transformer模型

Transformer模型于2017年被首次推出[29]。在此之前，主要是选择各种类型的RNN和卷积神经网络（CNN）来构建Seq2Seq模型。然而，这些基于RNN/CNN的模型存在很多问题，特别对于RNN构建的模型来说，其最大的问题是无法很好地处理具有长时期依赖性的序列。在处理长序列输入时，基于RNN的模型可能会遇到梯度爆炸和梯度消失的问题[23–24]，导致性能不佳。尽管有研究已经提出了一些更新的RNN结构，如长短期记忆（LSTM）[30]和门循环单元[31]，但这些更新的RNN结构随着序列变长也会出现问题。

由于Transformer模型的核心是多头注意力机制和自注意力机制，该模型显示出其在处理长时间依赖方面的强大能力。这些机制使模型能够自主选择更加重要的输入。Transformer模型很容易通过训练数据集学习时间耦合关系。在我们的研究中，一天被划分为96个时间步长，这使得输入序列变得更长；因此，毫无疑问，Transformer模型将是解决这个问题的合适模型。此外，多头注意力机制和自注意力机制也使得Transformer模型适用于更一般的情况。因为我们需要预测两个DR资源的灵活性，所以我们使用了这个更强大的工具。

Transformer模型的结构比较复杂，因此，我们不会解释详细的机制。关于Transformer模型更多的细节可以在参考文献[29]中找到。

3.3. 基于TCN的输入嵌入模块

在普通的Transformer模型中，输入需要经过一个“输入嵌入层”才能发送到内部结构。在NLP中，输入嵌入层的功能是使用一个维数低得多的向量来表示词的相对高维的独热编码。更一般地说，这可以看作是一种特征提取方法。基于此，我们找到了实现研究中输入特征提取的方法。

因为卷积操作是从原始输入中提取信息的强大工具，所以CNN可能是不错的选择。考虑到本研究中输入的是时间序列，一个可以捕获序列信息的结构自然会起作用。在各种基于CNN构建的模型中，2018年提出的“TCN”模型[32]是基于CNN的处理时间序列最先进的模型之一。本文之后将展示如何使用一种可以在原始Transformer模型中实现此类特征提取的TCN模型。

TCN模型的核心结构如图4所示。左图是“扩展因果卷积”，代表因果卷积和扩展卷积的集成，它使较短的序列可以表示较长的序列。连接到正方形的蓝线的数量是“内核大小”（在此图中，内核大小为3）。“d”是膨胀系数，代表连接到正方形的两条相邻蓝线之间的距离。我们可以看到，当内核大小为3时，深度为4的网络（层数）使最终输出（顶层的蓝色方块）包含了输入的所有信息。右图是“TCN模型中的残差块”，代表了一种设计结构，可以使网络更深而不会出现退化[33]。这种结构叫做“残差连接”（residual connection），是在参考文献[33]中被提

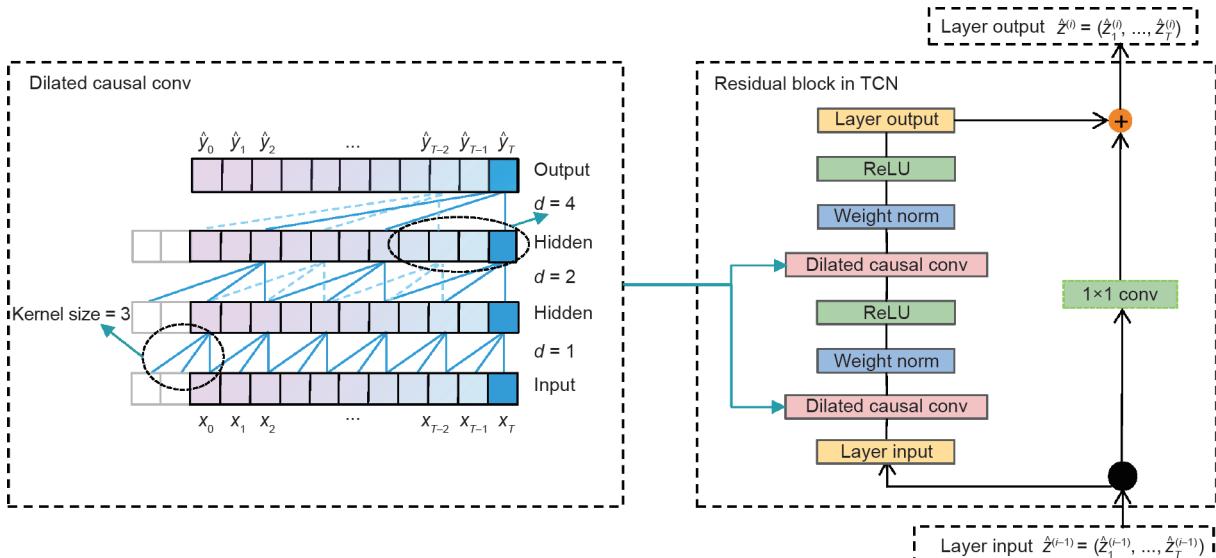


图4. TCN模型的核心结构。ReLU：整流线性单元。

出的。权重归一化(weight norm)[34]对层参数进行缩放，从而提高模型的性能。

最后，通过串联几个残差块，我们得到了TCN的整体模型，即“基于TCN的输入嵌入模块”。

需要注意的是，在TCN模型中，输入和输出的长度是相同的；然而，我们只能选择TCN结构顶部最后96个时间步长的输出作为Transformer模型的输入。这有两方面原因：一方面，最后96个输出通过合理的设计包含了输入序列的所有信息；另一方面，较短的序列可以减少Transformer模型的计算负担。我们将整个结构称为结合TCN的Transformer模型，如图5所示。可以看出，该模型结构正好实现了式(25)、(26)的形式。

3.4. 训练详情

3.4.1. 模型的输入和输出

在式(25)、(26)中，我们建立了预测的一般形式。在本节中，我们使得式(25)、(26)的表达形式更为详细。如前文所述，在不同的DS值下，模型的输出为 $\hat{P}_{EVA}(t)$ 和 $\hat{P}_{DHWSA}(t)$ 。对于输入，除了 $\hat{P}_{EVA}(t+k-1), \dots, \hat{P}_{EVA}(t), DS(t+k), \dots, DS(t)$ 和 \hat{P}_{EVA} 之外，我们还需要根据问题的特点指定包括 N 、 \dot{u}_{EVA} 、 \dot{u}_{DHWSA} 、 e_{EVA} 和 e_{DHWSA} 在内的变量。首先，我们为所有场景设置 $N=192$ 。由于本研究将一天分为96个时间步长，因此，这表明考虑了过去两天的输入。其他变量取决于不同的情况，包括

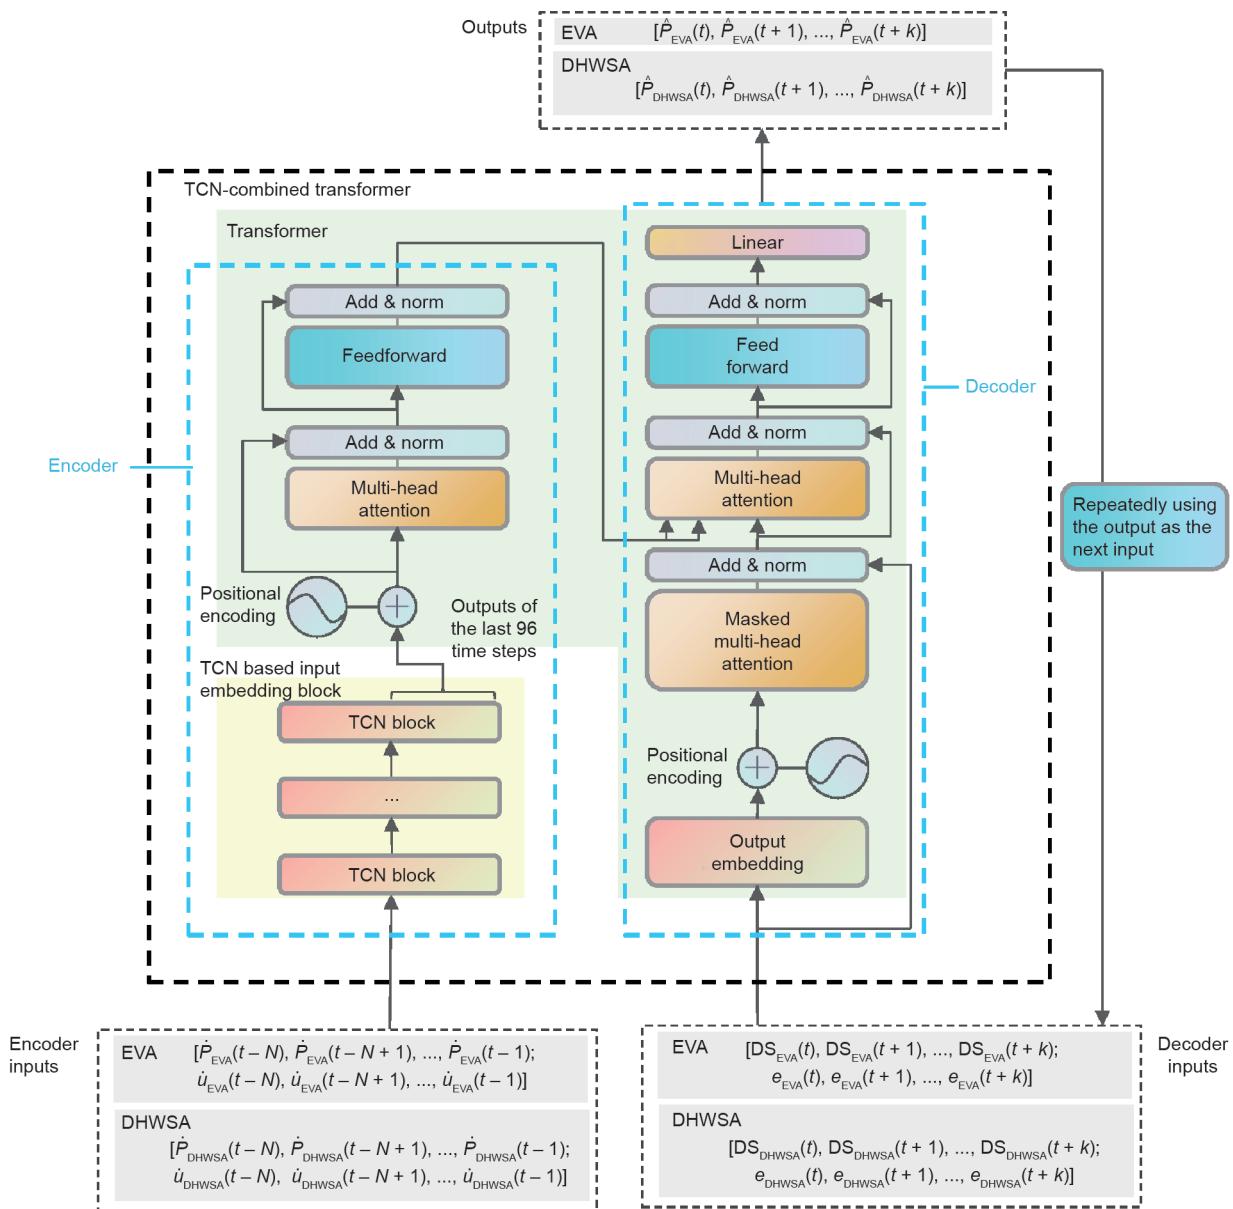


图5. 结合TCN的Transformer模型。

EVA/DHWSA 及策略 1 和 2。它们是单独引入的。

3.4.2. EVA 的模型输入和输出

对于策略 1，我们设置 $\dot{u}_{\text{EVA}} = \dot{0}$ 和 $[e_{\text{EVA}}(t+k), \dots, e_{\text{EVA}}(t)] = \dot{0}$ ，这意味着 Encoder 和 Decoder 中没有外部因素介入。在这种情况下，式 (25) 可以改写为式 (27)、(28)。

$$\begin{aligned} \hat{P}_{\text{EVA}}(t+k) &= \text{Decoder}\{\hat{P}_{\text{EVA}}(t+k-1), \dots, \hat{P}_{\text{EVA}}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); \text{Encoder}[\hat{P}_{\text{EVA}}]\} \end{aligned} \quad (27)$$

$$\dot{P}_{\text{EVA}} = [P_{\text{EVA}}(t-1), P_{\text{EVA}}(t-2), \dots, P_{\text{EVA}}(t-192)] \quad (28)$$

对于策略 2，考虑基础功率是根据分时电价设置的，在 \dot{u}_{EVA} 和 e_{EVA} 中，我们将分时电价作为外部因素，得到式 (29) ~ (31)。

$$\begin{aligned} \hat{P}_{\text{EVA}}(t+k) &= \text{Decoder}\{\hat{P}_{\text{EVA}}(t+k-1), \dots, \hat{P}_{\text{EVA}}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); e_{\text{EVA}}(t+k), \dots, \end{aligned} \quad (29)$$

$$\begin{aligned} e_{\text{EVA}}(t); \text{Encoder}[\dot{P}_{\text{EVA}}, \dot{u}_{\text{EVA}}]\} \\ \dot{u}_{\text{EVA}} = [u_{\text{EVA}}(t), u_{\text{EVA}}(t-1), \dots, u_{\text{EVA}}(t-192)] \quad (30) \\ = [c_{\text{ToU}}(t), \dots, c_{\text{ToU}}(t-192)] \end{aligned}$$

$$[e_{\text{EVA}}(t+k), \dots, e_{\text{EVA}}(t)] = [c_{\text{ToU}}(t+k), \dots, c_{\text{ToU}}(t)] \quad (31)$$

3.4.3. DHWSA 的模型输入和输出

DHWSA 的特点与 EVA 相似，因此对于策略 1，输入和输出与 EVA 的输入和输出相同，如式 (32)、(33) 所示。

$$\begin{aligned} \hat{P}_{\text{DHWSA}}(t+k) &= \text{Decoder}\{\hat{P}_{\text{DHWSA}}(t+k-1), \dots, \hat{P}_{\text{DHWSA}}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); \text{Encoder}[\hat{P}_{\text{DHWSA}}]\} \end{aligned} \quad (32)$$

$$\begin{aligned} \dot{P}_{\text{DHWSA}} &= [P_{\text{DHWSA}}(t-1), P_{\text{DHWSA}}(t-2), \dots, P_{\text{DHWSA}}(t-192)] \\ &\quad (33) \end{aligned}$$

对于策略 2，同理，我们得到式 (34) ~ (36)：

$$\begin{aligned} \hat{P}_{\text{DHWSA}}(t+k) &= \text{Decoder}\{\hat{P}_{\text{DHWSA}}(t+k-1), \dots, \hat{P}_{\text{DHWSA}}(t); \\ &\quad \text{DS}(t+k), \dots, \text{DS}(t); e_{\text{DHWSA}}(t+k), \dots, \\ &\quad e_{\text{DHWSA}}(t); \text{Encoder}[\dot{P}_{\text{DHWSA}}, \dot{u}_{\text{DHWSA}}]\} \end{aligned} \quad (34)$$

$$\begin{aligned} \dot{u}_{\text{DHWSA}} &= [u_{\text{DHWSA}}(t), u_{\text{DHWSA}}(t-1), \dots, u_{\text{DHWSA}}(t-192)] \\ &= [c_{\text{ToU}}(t), \dots, c_{\text{ToU}}(t-192)] \end{aligned} \quad (35)$$

$$[e_{\text{DHWSA}}(t+k), \dots, e_{\text{DHWSA}}(t)] = [c_{\text{ToU}}(t+k), \dots, c_{\text{ToU}}(t)] \quad (36)$$

3.4.4. 超参数设置

要对模型进行训练，必须有指定超参数。表 3 列出了本研究中所使用的超参数，Adam 算法在网络训练中表现良好，可以轻松应用于许多机器学习任务[35]。我们选择了 Adam 优化器来训练该网络。

表 3 结合 TCN 的 Transformer 模型的超参数

Model structure	Hyper parameters	Value
TCN-based input embedding block	Number of residual blocks	4
	Number of channels	64
	Kernel size	4
	Dropout rate	0.1
Transformer	Encoder layers	3
	Encoder heads	8
	Encoder feedforward layer dims	256
	Decoder layers	3
	Decoder heads	8
	Decoder feedforward layer dims	256
	Dropout rate	0.1

3.4.5. 训练数据集

我们需要指定训练数据集。根据所需的变量创建训练数据集，即式 (27) ~ (36) 中的输入和输出。EVA 和 DHWSA 灵活性预测的训练数据集将在下文进行介绍。需注意的是，因为不同场景 (EVA 或 DHWSA 在不同策略下) 的特征是不同的，因此我们需要训练几个不同的模型。

3.4.6. EVA 训练数据集

为了训练结合 TCN 的 Transformer 模型，我们假设所有分布式 EV 的历史信息，包括到达时间、出发时间、电池容量和充电状态，都可以由 EVA 收集。然后，基于式 (2) ~ (8)，我们产生了策略 1 下的基础电能消耗。基于式 (2) ~ (8)、(15)，我们得到了策略 2 下的基础电能消耗。因此，我们在策略 1 和 2 中获得了没有 DS 的基本调度功率 P_{EVA} 。基于基本功率，根据表 1，EVA 可以推导出每天在 $DS = 1$ 和 -1 时的 EV 充电/放电功率 \hat{P}_{EVA} 。

3.4.7. DHWSA 训练数据集

DHWSA 网络的训练需要 DHWS 的基本信息，包括物理参数、水温和开关信息。在收集了 DHWS 的历史数据后，基于式 (9) ~ (14)，我们产生了策略 1 下的基础电能消耗。基于式 (9) ~ (15)，我们产生了策略 2 下的基础电能消耗。因此，我们可以在策略 1 和 2 中获得没有 DS 的基本调度功率 P_{DHWSA} 。基于基本功率，根据表 1，EVA 可以推导出 $DS = 1$ 和 -1 时每天的 EV 充电/放电功率 \hat{P}_{DHWSA} 。

请注意，在策略 2 的情况下需要为 EVA 和 DHWSA 收集每天的分时电价。

3.5. 应用

经过训练，结合 TCN 的 Transformer 模型可以提供准

确的预测。在实时情况下，一旦我们想提前多步预测灵活性，就会使用一组新的EV/DHWS数据，并将其输入到不同电力消耗策略下的EVA/DHWSA训练过程中。由不同的DS值（包括 $DS = 0$ 和 $DS \neq 0$ ）激活的EVA/DHWSA所对应的功率可以被提前一步生成。例如，如果我们需要预测时间步长 $t+k$ 处的上调灵活性，我们可以将 $DS(t+k) = -1$ 作为解码器输入，得到 $DS(t+k) = -1$ 时预测功率在 $t+k$ 处的网络输出。接下来，我们将 $DS(t+k) = 0$ 作为解码器输入，得到 $DS(t+k) = 0$ 时预测功率在 $t+k$ 处的网络输出。根据式(16)，我们将 $DS(t+k) = -1$ 时的预测功率减去 $DS(t+k) = 0$ 时的预测功率来获得上调灵活性。然后，使用该输出作为下一个输入，可以推导出相应的提前多步功率。使用式(16)、(17)可以轻松得出提前多步的灵活性。

3.6. 算法总结

在本节中，我们将介绍算法1，对所提出的基于结合TCN的Transformer模型的灵活性预测的整体过程进行总结。需要注意的是，在应用中，EVA/DHWSA只需要在训练好模型后重复第6步即可。

Algorithm 1. Algorithm for the TCN-combined transformer-based DR flexibility prediction.

1. Prepare 4 TCN-combined transformer models to predict the flexibility of EVA and DHWS under strategies 1 and 2, respectively.
2. Get historical dataset of EVA and DHWSA considering their characteristics for strategy 2; ToU tariff should also be collected.
3. Specify the inputs and outputs of the model for EVA and DHWSA under different strategies based on Eqs. (27–36).
4. Set the model hyperparameters for EVA and DHWSA under different strategies.
5. Train the 4 models.
6. Input the real-time data of EV/DHWS to the network and achieve a one-step-ahead prediction. Then, repeatedly use the output as the next input to achieve the multi-step-ahead prediction; thus, the multi-step-ahead flexibility can be predicted using Eqs. (16) and (17).

4. 案例研究

为了证明所提出的基于结合TCN的Transformer的方法在EV和DHW灵活性预测中的有效性，本文进行了案例仿真研究，并在本节介绍了研究的结果。我们使用了一台配置为Intel® Core™ i7-7500U CPU @2.70-2.90 GHz、8 GB RAM、RTX2060的计算机，以及一台配置为6×Intel® Xeon® CPU E5-2678 v3 @ 2.50 GHz、11 GB RAM、RTX2080 Ti的云

服务器，来运行所有的模拟。

4.1. 基本数据

该模拟基于一个拥有2000 DHWS和1000 EV的居民区。EV停车行为的数据和参数来自参考文献[36]。DHWS使用行为的数据和参数来自参考文献[37]。上述关键参数如表4所示。这两种策略的数据来自每年的256个工作日。选取前196天组成Transformer模型的训练数据集。为避免网络的过度拟合，选取剩余的197~226天作为验证数据集。最后，从第227~256天中随机选取30天测试算法的性能。EV充电站和居民区的分时电价如图6所示。

表4 EV和DHW的一些参数

Parameter	Value	Parameter	Value
P_{fast}	9 kW	E_{\max}	$0.9 \times 30 \text{ kW}\cdot\text{h}$
P_{slow}	3.3 kW	E_{\exp}	$0.85 \times 30 \text{ kW}\cdot\text{h}$
P_{dis}	-3.3 kW	P_b	3 kW
E_{ms}	$0.5 \times 30 \text{ kW}\cdot\text{h}$	V_{tank}	300 L

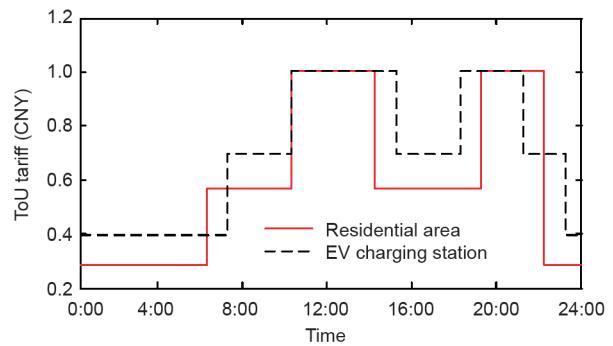


图6. EV充电站和居民区的分时电价。

由于EV和DHWS在用电时间上存在差异，DHWS在一天内的研究范围是00:00~24:00，而EV的研究范围是12:00至次日12:00。在本研究中，一个时间步长是15 min，因此，一天可以分为96个时间步长。

4.2. Transformer模型的收敛性能

在本研究中，我们使用训练数据集中目标值与网络输出之间的均方误差作为损失函数。图7说明了两种策略下的网络学习性能。如图7所示，所有损失函数在开始的一些epoch内都经历了急剧下降，此外，随着epoch的增加，损失函数在 10^{-5} 附近呈现稳定以及轻微的下降。尽管有轻微的波动，但验证集上的损失函数值仍保持下降趋势，没有出现任何异常激增，这表明学习过程中没有出现过拟合。总的来说，综合考虑4 h (600个epoch)和6 h (1000个epoch)的总训练时间以及较高的收敛性能，所

提出的网络结构实现了复杂度和性能之间的平衡。

4.3. 灵活性预测结果分析

为了评估 EVA 和 DHWSA 的灵活性在不同维持时间下的预测性能，我们比较了策略 1（不考虑优化功耗）和策略 2（考虑优化功耗）在 6 种场景下的结果：① $DS = -1$ 维持 15 min；② $DS = -1$ 维持 30 min；③ $DS = -1$ 维持 60 min；④ $DS = 1$ 维持 15 min；⑤ $DS = 1$ 维持 30 min；⑥ $DS = 1$ 维持 60 min。此外，为了验证我们提出的多步灵活性预测方法能否预测较长时段，我们选择预测接下来一天的灵活性，这意味着我们需要检验对于 96 个时间步长的提前预测的准确性，因此， $k = 96$ 。所以，我们的多步预测是通过重复进行一步预测来实现的。在实时情况下，我们可以根据情况随时预测任何提前一步的灵活性。

为了说明所提出的基于结合 TCN 的 Transformer 模型的算法的优越性，我们还使用了 LSTM 方法（一种更新的 RNN 结构，见 3.2 节）来预测本节中描述的灵活性。经过训练的 LSTM 包含一个输入层、两个隐藏层，每个隐藏层有 128 个节点。

4.3.1. 一天内的灵活性预测结果

图 8 至图 11 显示了在测试数据集中随机选择一天的灵

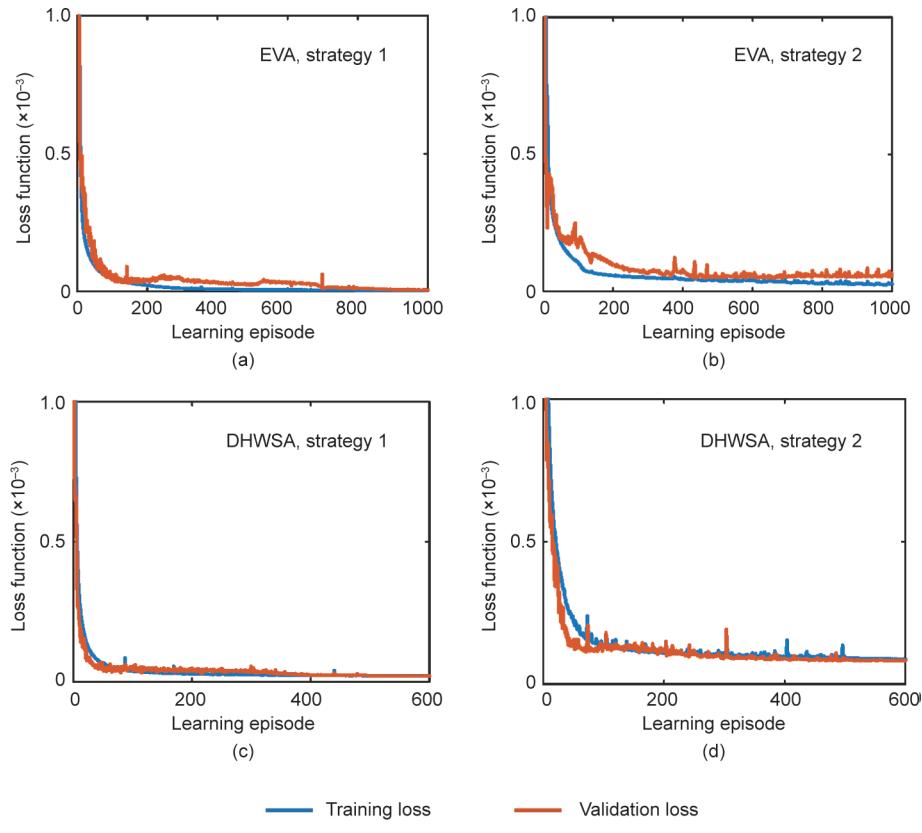


图 7. EVA 和 DHWSA 在两种策略下的损失函数。

活性预测结果。从图中可以看出，无论是结合 TCN 的 Transformer，还是 LSTM，其灵活性峰值都比其他值稍难预测。但总的来说，与实际值相比，结合 TCN 的 Transformer 的预测结果要比 LSTM 的预测结果更准确。请注意，如 2.4 节和 2.5 节所述，灵活性的实际值是通过实时向 EV 和 DHWSA 发送 DS 得出的。

如图 8 至图 11 所示，不同的维持时间下相对应的灵活性也不同。灵活性大小随着维持时间的增加而减小。由于 DR 资源是分散的，且不确定性很大，很难在较长时间内提供聚合稳定的灵活性。因此，应将 DR 程序中 DR 资源的维持时间设置为较小的值，有利于激活更多潜在的 DR 灵活性。

此外，不同时期使用策略 1 和策略 2 的灵活性也不同。EVA 的灵活性主要出现在 16:00 至第二天 8:00。策略 2 的正向灵活性（从电网吸收功率）大于策略 1，而策略 2 的负向灵活性（向电网释放功率）小于策略 1。DHWSA 的灵活性一整天都存在。策略 2 在 8:00~24:00 的正向灵活性较高，负向灵活性较低；而策略 2 在 0:00~8:00 的正向灵活性较低，负向灵活性较高。另外，维持时间越低，差异越显著。

此外，在相同的策略下，DR 资源在不同的场景下呈

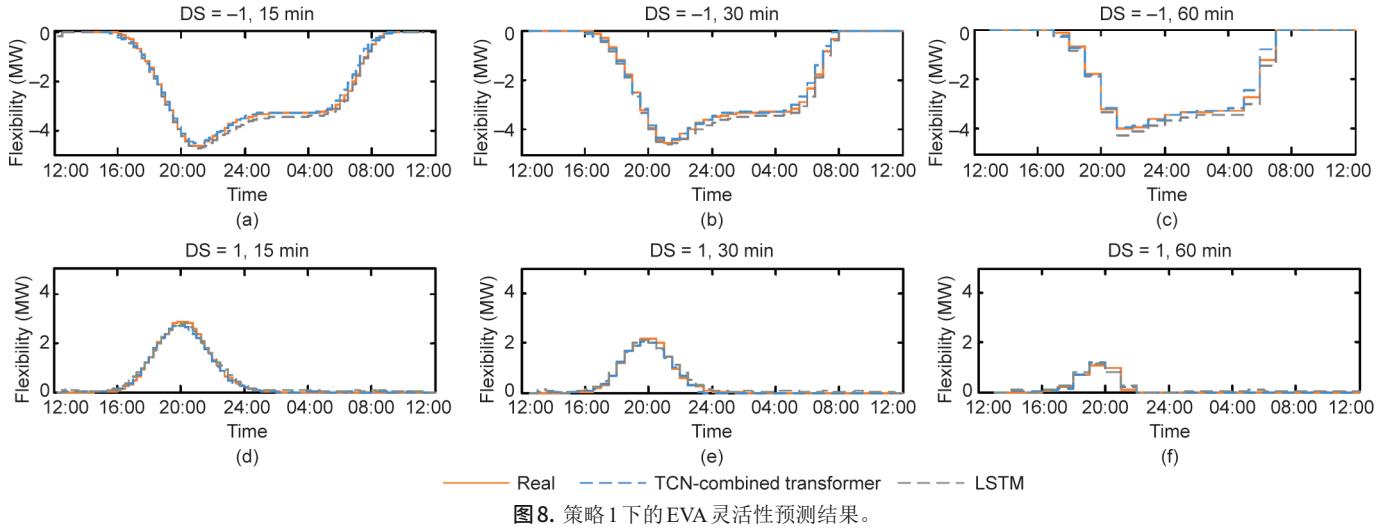


图8. 策略1下的EVA灵活性预测结果。

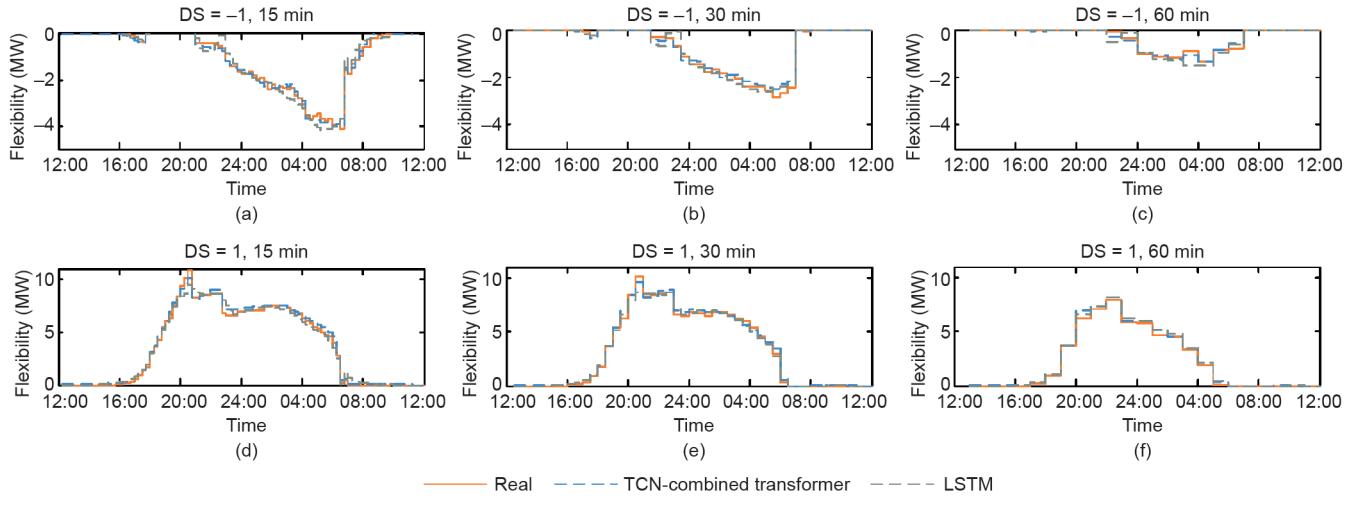


图9. 策略2下的EVA灵活性预测结果。

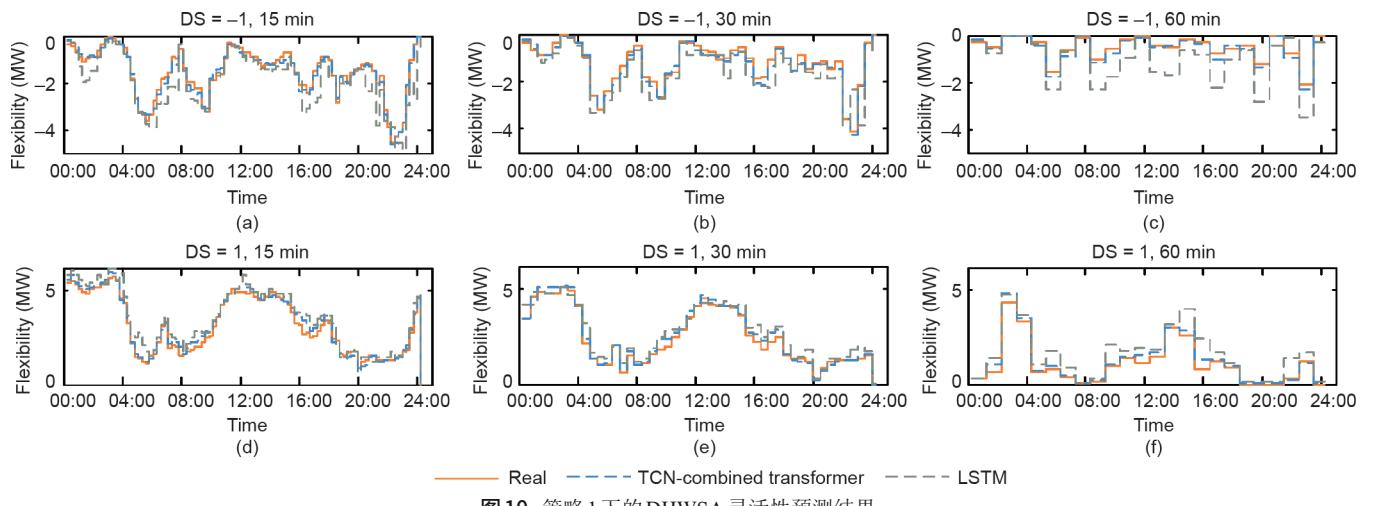


图10. 策略1下的DHWSA灵活性预测结果。

现出不同的特点。对于EVA，一旦充电超过最小荷电状态，EV就有可能放电。然而，当接近出发时间时，几乎不存在放电来满足EV的能量需求。因此，当 $DS = -1$ 时，

16:00至第二天8:00存在正向灵活性，最大值为-4.5 MW/15 min。 $DS = 1$ 时，快速充电模式下EV的荷电状态快速增加；然而，由于最大电池容量的限制，EV并没有继续

提供灵活性。因此，当 $DS = 1$ 时，EVA 从 16:00 到 24:00 的最大灵活性约为 $3 \text{ MW}/15 \text{ min}$ 。对于 DHWSA，正负灵活性在预测时段内分布相对均匀。如参考文献[37]中所述，由于 DHWS 使用的变化（如晚上洗澡，早上淋浴，13:00~16:00 几乎不使用，使用后温度延迟），负向灵活性在 17:00 左右达到了 $-4.5 \sim -4.8 \text{ MW}/15 \text{ min}$ 的低点，而正向灵活性在 00:00~8:00 之间达到了峰值，大约为 $-5 \text{ MW}/15 \text{ min}$ 。

4.3.2. 连续 30 天的预测准确率

表 5 至表 8 提供了不同策略和场景下 30 天预测的平均

绝对误差（预测值与实际值之间误差的平均绝对值，MAE）的信息。从图 8 至图 11 和表 5 至表 8 可以看出，所提出的结合 TCN 的 Transformer 模型的预测灵活性比 LSTM 更接近真实值。在更简单的场景中，即策略 1 下的 EVA 预测，结合 TCN 的 Transformer 模型的表现略好于 LSTM。随着场景变得更加复杂，如策略 2 下的 EVA 预测与策略 1 和 2 下的 DHWSA 预测（由于 DHWS 用户数量多，DHWSA 的复杂度更高），结合 TCN 的 Transformer 模型的预测准确度相对优于 LSTM。如 3.2 节所述，LSTM 是一种更新的 RNN 结构，可以显著改善 RNN 的长时间依

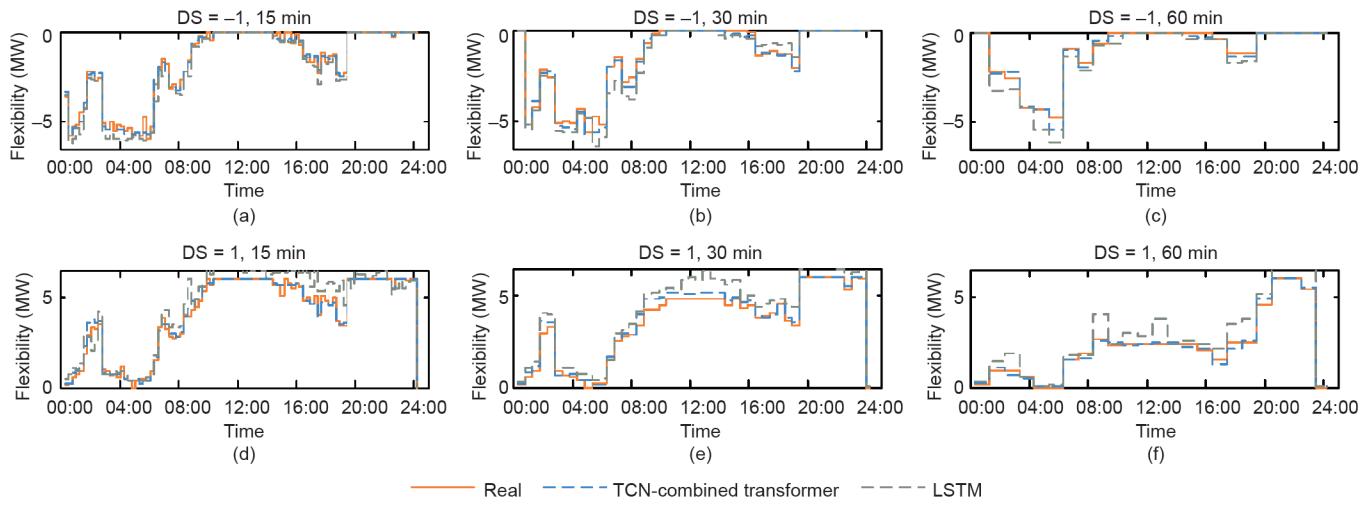


图 11. 策略 2 下的 DHWSA 灵活性预测结果。

表 5 策略 1 下 30 天 EVA 预测结果的 MAE

DS	Prediction method	15 min (MW)	30 min (MW)	60 min (MW)
1 (down)	LSTM	0.055	0.056	0.042
	TCN-combined transformer	0.028	0.027	0.015
-1 (up)	LSTM	0.105	0.102	0.106
	TCN-combined transformer	0.085	0.083	0.088

表 6 策略 2 下 30 天 EVA 预测结果的 MAE

DS	Prediction method	15 min (MW)	30 min (MW)	60 min (MW)
1 (down)	LSTM	0.230	0.180	0.158
	TCN-combined transformer	0.177	0.155	0.148
-1 (up)	LSTM	0.147	0.116	0.092
	TCN-combined transformer	0.094	0.073	0.052

表 7 策略 1 下 30 天 DHWSA 预测结果的指标

DS	Prediction method	15 min (MW)	30 min (MW)	60 min (MW)
1 (down)	LSTM	0.273	0.2519	0.274
	TCN-combined transformer	0.147	0.1480	0.121
-1 (up)	LSTM	0.282	0.1987	0.178
	TCN-combined transformer	0.185	0.1930	0.175

表8 策略2下30天DHWsA预测结果的指标

DS	Prediction method	15 min (MW)	30 min (MW)	60 min (MW)
1 (down)	LSTM	0.234	0.191	0.169
	TCN-combined transformer	0.139	0.141	0.138
-1 (up)	LSTM	0.221	0.217	0.179
	TCN-combined transformer	0.140	0.163	0.143

赖问题。随着分时电价、用户数量、用户行为随机性等影响因素的增加，LSTM仍然难以完全捕获输入序列中的信息。在一般情况下，通过多头注意力和自注意力机制，结合TCN的Transformer模型可以很容易地通过输入序列学习时间序列信息。结果表明，结合TCN的Transformer模型的预测灵活性接近于真实值且准确度高，更适合于不同用电场景下对DR资源的灵活性预测。

4.4. 灵活性预测方法的应用前景

如2.1节所述，负向灵活性可提供向上储备，正向灵活性可提供向下储备。从预测来看，聚合DR资源的灵活性是通过提前多步获得的，聚合商自有资源的可调度灵活性可以提前和实时预测。获得的预测结果可为聚合商或上级调度机构的决策提供参考，从而实现聚合商与不同级别电力系统运营商，如输电系统运营商（TSO）和配电系统运营商（DSO）等的进一步合作。

在提前预测时，通过输入不同的DS信号，可以获得灵活性的数量和维持时间，用于掌握灵活性的整体分布，对资源灵活性进行总体评估。根据预测结果，聚合商可以在电能和辅助服务市场中交换DR资源的灵活性。对于DR用户而言，可以节约电力成本。对电力系统运营商而言，可提前保证DR资源的用电量和电力系统的备用容量，有利于减少DR资源的随机用电行为和可再生能源生产的不确定性对电力系统的影响，从而促进负荷平衡，确保部分应急储备。例如，根据图10，在策略2下，EV在20:00~24:00期间有足够的向下储备灵活性。4:00~8:00之间的向上储备灵活性在较短的维持时间（15~30 min）内分布较为均匀，24:00~8:00之间在维持时间达到60 min时向上储备灵活性呈递减趋势。基于这一预测结果，未来一天在储备市场中，聚合商倾向于在20:00~24:00之间提供向下储备，并在4:00~8:00之间提供向上储备，这是一个更稳健的决策。因此，备用容量可用于系统运行，例如在TSO层面调节频率或在DSO层面缓解拥塞。

在实时预测时，可以通过持续滚动预测来更新前一天定义的DR资源的灵活性和维持时间。由于实时预测是超短期预测，因此比前一天预测更准确。将更新后的灵活

性相应地报告给系统操作员后，系统操作员可以及时了解可用储备。此外，聚合商可能需要参与日内市场、平衡市场和实时运行；在这些聚合商优化问题中，灵活性的预测定义了分布式能源功率的上下限，因此，在聚合商优化问题中，更新灵活性是必要的。

5. 结论

本研究提出了一种基于结合TCN的Transformer模型的算法，用于预测DR中聚合的EV和DHWS在不同维持时间下的灵活性大小。该预测是基于对EV和DHWS以及DS的历史功耗行为的网络训练。通过在不同功耗策略下对一组住宅EV和DHWS终端用户的案例进行研究，验证了灵活性预测的准确性。我们可以推断，灵活性大小会随着维持时间的增加而减少。总的来说，所提出的基于结合TCN的Transformer模型的灵活性预测方法可以支持日常电网运行中的DR调度。

缺乏足够的数据是深度学习技术在电网领域应用面临的主要挑战。这种基于学习的方法在工程中通常没有足够的数据，所测数据大多质量较差。为了进一步应用我们提出的灵活性方法，我们应该利用智能电表的快速发展，积极考虑并进行有益的尝试，以获取真实的数据。此外，进一步发展数据生成技术非常重要，可以在难以获得准确数据的情况下补充大量数据。由于实际数据在传输过程中可能会丢失，发展相应的数据修复技术也有助于提高数据质量。

致谢

本工作得到了国家自然科学基金项目(51877078、52061635102)和北京新星计划项目(Z201100006820106)的支持。

Compliance with ethics guidelines

Junjie Hu, Huayanran Zhou, Yihong Zhou, Haijing

Zhang, Lars Nordström, and Guangya Yang declare that they have no conflicts of interest or financial conflicts to disclose.

References

- [1] Hu J, Zhou H, Li Y, Hou P, Yang G. Multi-time scale energy management strategy of aggregator characterized by photovoltaic generation and electric vehicles. *J Mod Power Syst Clean Energy* 2020;8(4):727–36.
- [2] Kumar A, Sekhar C. Demand response based congestion management in a mix of pool and bilateral electricity market model. *Front Energy* 2012;6(2):164–78.
- [3] Hu J, Yang G, Ziras C, Kok K. Aggregator operation in the balancing market through network-constrained transactive energy. *IEEE Trans Power Syst* 2019;34(5):4071–80.
- [4] Xue Y, Yu X. Beyond smart grid—cyber-physical-social system in energy future. *Proc IEEE* 2017;105(12):2290–2.
- [5] International energy agency. Harnessing variable renewables: a guide to the balancing challenge. Paris: OECD Publishing; 2011.
- [6] Chen Z, Sun Y, Ai X, Malik SM, Yang L. Integrated demand response characteristics of industrial park: a review. *J Mod Power Syst Clean Energy* 2020;8(1):15–26.
- [7] Fattah J, Samadi M, Erol-Kantarci M, Schriemer H. Transactive demand response operation at the grid edge using the IEEE 2030.5 standard. *Engineering* 2020;6(7):801–11.
- [8] Li Z, Guo Q, Sun H, Wang J. Storage-like devices in load leveling: complementarity constraints and a new and exact relaxation method. *Appl Energy* 2015;151:13–22.
- [9] Sanandaji BM, Vincent TL, Poolla K. Ramping rate flexibility of residential HVAC loads. *IEEE Trans Sustain Energy* 2016;7(2):865–74.
- [10] Hu K, Li W, Wang L, Cao S, Zhu F, Shou Z. Energy management for multi-microgrid system based on model predictive control. *Front Inf Technol Electron Eng* 2018;19(11):1340–51.
- [11] Vivekananthan C, Mishra Y, Ledwich G, Li F. Demand response for residential appliances via customer reward scheme. *IEEE Trans Smart Grid* 2014;5(2):809–20.
- [12] Wu J, Xue Y, Xie D, Yue D, Wen F, Zhao J. Evaluation and simulation analysis of reserve capability for electric vehicles. *Autom Electr Power Syst* 2018;42(13):101–7. Chinese.
- [13] Wang J, Jia Y, Mi Z, Chen H, Fang H. Reserve service strategy of electric vehicles based on double-incentive mechanism. *Autom Electr Power Syst* 2020;44(10):68–76. Chinese.
- [14] Yao W, Zhao J, Wen F, Xue Y, Chen F, Li L. Frequency regulation strategy for electric vehicles with centralized charging. *Autom Electr Power Syst* 2014;38(9):69–76. Chinese.
- [15] Zhang B, Xu G. Rolling horizon optimization for grid-connected electric vehicles considering demand difference. *Autom Electr Power Syst* 2020;44(13):106–14. Chinese.
- [16] Han B, Lu S, Xue F, Jiang L. Day-ahead electric vehicle aggregator bidding strategy using stochastic programming in an uncertain reserve market. *IET Gener Transm Distrib* 2019;13(12):2517–25.
- [17] Wang Yi, Hug G, Liu Z, Zhang N. Modeling load forecast uncertainty using generative adversarial networks. *Electr Power Syst Res* 2020;189:106732.
- [18] Chen K, Chen K, Wang Q, He Z, Hu J, He J. Short-term load forecasting with deep residual network. *IEEE Trans Smart Grid* 2019;10(4):3943–52.
- [19] Hong T, Pinson P, Wang Yi, Weron R, Yang D, Zareipour H. Energy forecasting: a review and outlook. *IEEE Open Access J Power and Energy* 2020;7:376–88.
- [20] Divshali PH, Evens C. Behaviour analysis of electrical vehicle flexibility based on large-scale charging data. In: 2019 IEEE Milan PowerTech; 2019 Jun 23–27; Milan, Italy; 2019.
- [21] Sajjad IA, Chicco G, Napoli R. Definitions of demand flexibility for aggregate residential loads. *IEEE Trans Smart Grid* 2016;7(6):2633–43.
- [22] Paridari K, Nordström L. Flexibility prediction, scheduling and control of aggregated TCLs. *Electr Power Syst Res* 2020;178:106004.
- [23] Hochreiter S, Bengio Y, Frasconi P, Schmidhuber J. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. In: John FK, Stefan CK, editors. A field guide to dynamical recurrent networks. New York: IEEE Press; 2001. p. 237–44.
- [24] Bengio Y, Simard P, Frasconi P. Learning long-term dependencies with gradient descent is difficult. *IEEE Trans Neural Netw* 1994;5(2):157–66.
- [25] Lu Z, Li H, Qiao Y. Power system flexibility planning and challenges considering high proportion of renewable energy. *Autom Electr Power Syst* 2016;40(13):147–57. Chinese.
- [26] Parlors AG, Rais OT, Atiya AF. Multi-step-ahead prediction using dynamic recurrent neural networks. *Neural Netw* 2000;13(7):765–86.
- [27] Bao Y, Xiong T, Hu Z. Multi-step-ahead time series prediction using multiple-output support vector regression. *Neurocomputing* 2014;129:482–93.
- [28] Sutskever I, Vinyals O, Le QV. Sequence to sequence learning with neural networks. 2014. arXiv:1409.3215v3.
- [29] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. 2017. arXiv:1706.03762v5.
- [30] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Comput* 1997;9(8):1735–80.
- [31] Chung J, Gulcehre C, Cho K, Bengio Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. 2014. arXiv:1412.3555v1.
- [32] Bai S, Kolter JZ, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. 2018. arXiv:1803.01271.
- [33] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition; 2016 Jun 27–30; Las Vegas, NV, USA; 2016.
- [34] Salimans T, Kingma DP. Weight normalization: a simple reparameterization to accelerate training of deep neural networks. 2016. arXiv:1602.07868.
- [35] Kingma DP, Ba JL. Adam: a method for stochastic optimization. 2017. arXiv:1412.6980v9.
- [36] Luo Z, Hu Z, Song Y, Xu Z, Lu H. Optimal coordination of plug-in electric vehicles in power grids with cost-benefit analysis—part II: a case study in china. *IEEE Trans Power Syst* 2013;28(4):3556–65.
- [37] Sandels C, Widén J, Nordström L. Forecasting household consumer electricity load profiles with a combined physical and behavioral approach. *Appl Energy* 2014;131:267–78.