arXiv:2304.05174v1 [cs.LG] 11 Apr 2023

结合统计学与机器学习算法的电力需求预测：乌克兰案例研究

T. Gonz´alez Grand´on[a]、J. Schwenzer[b]、T. Steens[c]、J. Breuing

[a]弗伦斯堡欧洲大学，*Munketoft 3*，*24937* 弗伦斯堡[b]奥得河畔法兰克福维亚德里纳欧洲大学，*Grosse Scharrnst. 59*，德国[c]德国航空航天中心网络能源系统研究所，*Carl-von-Ossietzky-Str. 15*，德国

摘要

本文提出一种结合统计学与机器学习的新型混合方法，用于预测全国电力需求。由于未来能源系统的投资与运营需要具备小时分辨率的长期电力需求预测，我们的数学模型填补了能源预测领域的一项空白。该方法基于乌克兰2013年至2020年的电力消费小时数据构建。为此，我们分析了电力消费小时、日和年时间序列的内在结构。利用宏观经济回归分析评估长期年度趋势。中期模型整合温度和日历回归变量，以描述其内在结构，并结合ARIMA和长短期记忆网络（LSTM）这两种基于模式的“黑箱”方法来描述误差项。短期模型通过日历回归变量捕捉小时季节性，并使用多个自回归移动平均模型处理残差。结果表明，最佳预测模型由多个回归模型与用于残差预测的长短期记忆网络混合模型组合而成。我们的混合模型在以小时分辨率预测长期电力消费方面表现出色。对两年期样本外预测（共17520个时间步）的分析显示，其准确率达到96.83%。

关键词：国家电力需求、预测、ARIMA、长短期记忆网络。

电子邮件地址：tatiana.grandon@uni-flensburg.de (T. Gonz´alez Grand´on)，johannes.m.schwenzer@gmail.com (J.Schwenzer)，thomas.steens@dlr.de (T.Steens)，julia@breuing.eu (J. Breuing)

*2023*年*4*月*12*日

1. 引言

电力在各国的增长与发展中发挥着重要作用。事实证明，无论是在发展中地区还是工业化地区，电力消费都在经济增长和生产低碳转型过程中发挥着重要作用 [1, 2, 3]。因此，准确预测负荷需求对于任何国家的战略决策都十分重要。这是一个正在开展深入研究的领域，因为即使预测准确度得到极小的改善，也可能价值数百万欧元 [4, 5]。例如， [6] 据估计，预测误差仅降低 1%，就使英国一家电力公用事业公司每年的运营成本减少了1,000 万英镑。尽管如此，现有的需求预测文献仍然是科学家和决策者面临的一项挑战 [7, 8]。

电力系统运行和发电设施更新投资需要不同时间范围、不同准确度的预测。根据时间范围和时间分辨率，预测可分为短期、中期和长期。短期负荷预测（STLF）对于日前或日内电力市场运行尤为重要。短期负荷预测的时间范围为一天或一周，时间分辨率为小时级或分钟级。中期负荷预测（MTLF）主要涉及燃料进口和维护调度。中期负荷预测的时间范围以月为尺度 [9], ，而时间分辨率通常以日为尺度。长期负荷预测（LTLF）对于电力系统规划（发电、输电和配电）以及新建发电机组的投资至关重要。长期负荷预测的时间范围从几年到十年不等，粒度为月级 [10]。然而，在当今能源转型背景下，许多决策流程和情景分析——例如整合波动性较大的可再生能源、终端用户灵活性、大规模电动出行或其他Power-to-X技术——都需要一个能够覆盖多个时间范围的模型。随着可再生能源发电占比不断提高，以及电力在一次能源消费中的渗透率持续上升，以精细分辨率进行准确的长期负荷预测至关重要。因此，作者填补了小时分辨率准确长期负荷预测模型方面的知识空白。

1.1. 文献综述

负荷预测模型通常可分为两大类，即经典统计技术（CST）和基于机器学习（ML）的现代统计学习方法。最广泛使用的经典统计方法是多元回归 [11, 12, 13, 14, 15, 16, 17], 和自回归结构 [18, 19, 20, 21, 22]。多元回归和时间序列自回归方法都要求预先定义模型结构。文中研究的回归模型用于月粒度的长期负荷预测，其预测准确率达到平均绝对百分比误差（MAPE）2.6%。ARIMA模型基于这样的假设：数据具有趋势、季节性、自相关和非平稳性等内在结构 [23]。综述中涉及的ARIMA预测模型用于短期负荷预测，平均MAPE值为3.9%。

相反，神经网络等机器学习模型通过历史数据进行训练，因此模型结构是基于事后确定的 [24]。用于电力预测的最广泛应用的机器学习方法是人工神经网络（人工神经网络） [25, 26, 27, 28, 29]和循环神经网络（RNN） [30, 31, 32]。前一种方法的预测准确度达到平均绝对百分比误差为 3.7%，而后一种 RNN 方法的平均绝对百分比误差为 3.6%。

CST和机器学习都旨在通过最小化定义的损失函数来提高预测准确度。不同之处在于，如何执行预测值与实际值之间误差函数的最小化。CST使用线性过程，而机器学习使用非线性算法。因此，CST方法通常计算复杂度较低 [33] 但机器学习方法正变得越来越受欢迎，因为它们还会考虑电力需求的非线性行为。尽管如此，机器学习方法主要用于短期负荷预测。截至目前，关于其长期预测能力的研究仍然有限 [34], 因此本文聚焦于此。此外，机器学习方法充当黑箱，因此无法预先纳入负荷与其他变量之间的具体关系。一些文章，如Nichiforov等人 [21], 比较了这两种方法，并得出结论：ARIMA模型的预测误差较低，其平均绝对百分比误差为15%，而人工神经网络模型的预测误差较高。此外，Chuang等人 [35] 比较了ARIMA和人工神经网络模型，以预测台湾的能源消耗。他们得出结论，单变量ARIMA模型表现更好。然而，上述文章分别评估了不同的预测方法，而不是将它们结合起来。

国家电力需求及其小时曲线的预测方法通常基于对当前负荷曲线的外推[8, 36, 37]。一些作者，如 Andersen 等人 [38]，引入了一种采用 CST 进行具有小时分辨率的长期负荷预测的模型。然而，他们的模型要求获取一个国家内单个用户的小时计量数据。大多数工业化国家通常无法获得如此大量的用户计量设备数据，更不用说发展中国家了。我们的研究受到 Pielow 等人 [11] 和 Sotiropoulos 等人 [39]工作的启发。前者采用傅里叶级数进行短期负荷预测，并通过线性回归将其按长期增长率进行缩放。Sotiropoulos 等人 [39]提出了一个用于日均值的中期模型和一个用于小时残差的短期模型。两个时间范围均由包含外生回归变量的确定性部分和通过自回归项建模的随机部分组成。尽管我们受到该方法的启发，但我们将模型划分为三个时间范围，而不是两个（以纳入长期短期负荷预测）。此外，为了提高预测准确度，同时理解影响不同时间范围的驱动因素，我们结合了 CST 和机器学习方法。目前，与本文类似，研究人员正在研究 CST 与机器学习模型的组合，以提升预测准确度并弥补各自方法的不足。预测组合方法称为集成或混合预测，是一种已得到成功应用的适用工具 [40, 41]。Chang 等人 [42] 使用混合 ARIMA-NN模型预测台湾的风力发电，但该方法仅适用于短期预测。Wang 等人 [43]结合季节性自回归综合移动平均（SARIMA）和神经网络模型，并采用方差-协方差方法进行非等权加权。Laouafi 等人 [44] 提出了一种组合模型，尤其能够改善特殊日的预测。例如，法国公共假日的结果显示，平均绝对百分比误差为 0.863%。这些研究结果显示了混合模型的潜力，但目前它们仅用于短期负荷预测。

据我们所知，目前尚缺乏探讨如何采用混合方法进行小时分辨率长期负荷预测的研究。一些作者已探讨过小时尺度的长期建模问题，例如 [38, 11, 39, 20]。这些研究的不足之处在于，模型选择单一，而且均基于 CST。

本文的主要目的是介绍一种新颖的混合预测方法，即经典统计方法-循环神经网络方法，用于以长期小时分辨率预测一个国家的总体电力需求。作为案例研究，我们评估了

来自 [45]的乌克兰2013年至2020年数据。

本文的主要贡献如下:

1.提出了一种具有小时分辨率的长期预测模型，遵循经典方法，其概念源自回归分析和ARIMA模型。2.提出了一种混合CST-LSTM模型，用于预测误差，以校正CST并提高预测准确率。 3. 使用四个统计参数展示了每种模型的比较结果及其缺点。 4. 给出了包括开源代码在内的详细计算方法，该方法可实现完全自动化，并可复现，以用于其他国家未来的负荷预测。

本文其余部分的组织结构如下。第2节概述乌克兰的电力行业。第3节介绍相应长期、中期和短期成分的模型分解和统计描述。第4节通过预测2019年和2020年的电力需求，展示并检验算法的性能。第5节总结本研究并阐述未来的研究计划。

2. 乌克兰电力需求概述

乌克兰是一个发展中国家，目前正经历政治和经济危机。该国电力消费的变化在其能源安全困境中发挥着日益关键的作用。乌克兰电力行业已经完成改革，将乌克兰电网接入欧洲大陆电网的计划已经提出，目前正在推进中 [46]。

电力消费受到宏观经济因素的影响，这些因素影响负荷序列趋势和年度周期性。图1展示了乌克兰2001年至2020年的电力需求。上升趋势在2009年因全球金融危机的影响而中断。此外，克里米亚危机导致年度总电力需求大幅下降30太瓦时。这一下降部分可由克里米亚被俄罗斯吞并来解释，因为该半岛已不再与乌克兰电网相连。克里米亚电力需求约占危机前水平的5%， [47], 因此只有10太瓦时可归因于此。危机前，顿巴斯地区是电力需求的第二大贡献者。2014年，该地区占乌克兰负荷的19%。其占比

由于经济衰退 [48]，在 2018 [45] 降至 9%。这突显了三个通常会影响电力需求时间序列的宏观经济变量：人口、GDP 和 GDP 增长率。

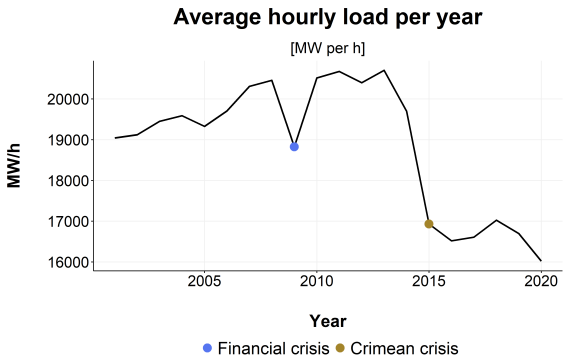

Fi图1：乌克兰在2000年至2020年期间的小时负荷年平均值。

中期和短期模型刻画了时间序列的季节性模式。图 2 展示了乌克兰2019年全年每天以小时分辨率记录的电力需求。通过按日分辨率呈现的红色区域，可以看出中期季节性负荷模式——冬季需求有所增加。横轴以小时分辨率显示了每日短期峰值负荷的反复变化。

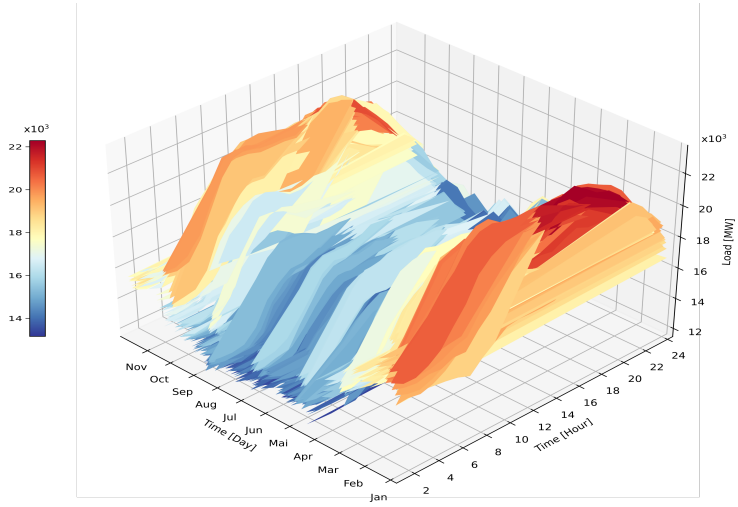

Fig图2：2019年1月1日至2019年12月31日乌克兰电力需求数据。

温度是刻画电力需求季节性的重要变量。本研究的温度数据取自 [49]。图 3 左图展示了 2018年温度和负荷的月度移动平均值，右图则通过散点图呈现这两个变量之间的相关结构。左侧图表表明，在一年中的大部分时间里，温度与负荷呈非线性的反向变化模式。同时，右图中的散点呈曲棍球杆形状：负荷水平在低温时达到最高，而高温时的负荷略高于较温和天气下的负荷。在乌克兰，居民负荷中有 5.3% 来自取暖设备，只有 1.9% 来自制冷设备 [47]。

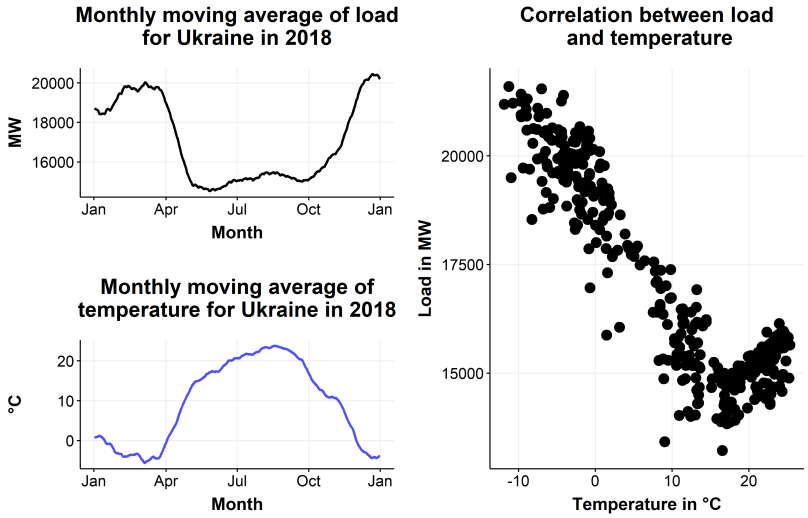

图3：温度与负荷的比较。

3. 数学模型

由于宏观经济和人口统计变量会影响年度趋势，温度、年内模式和日历变量会影响每日负荷曲线。因此，模型被分为三个部分。consequently，它由长期、中期和短期部分组成。通过将负荷拆分为其组-成部分，可以确定多个季节性的幅度以及外生变量的影响

变量不会随时间推移而增加。因此，选择加法方法：

$$\bar{D}(t(y,d,h)) = \bar{D}_L(y) + \bar{D}_M(d,y) + \bar{D}_S(y,d,h) \tag{1}$$

其中，$\bar{D}(t)$表示时间 $t(y、d、h)$的小时电力需求，而 $\bar{D}_L(\cdot)$ $\bar{D}_M(\cdot)$和 $\bar{D}_S(\cdot)$分别表示长期、中期和短期分量，其时间分辨率分别为年（y）、日（d）和小时（h）。

3.1. 长期经典回归模型

我们首先建立了一个长期模型，根据宏观经济因素预测每年的小时负荷平均值。我们用 $\bar{D}_L(y)$表示年份 $y \in \{2001, \ldots, 2018\}$ 的小时负荷平均值。若令 $t_1 \in \{1, 2, \ldots, 8\}$，则其定义为：

$$\bar{D}_L(t_1) = \frac{1}{8760} \sum_{j=1+8760(t_1-1)}^{8760*t_1} D_h(j)$$

其中，D_h 是数据集中的给定小时需求量。为准备数据集，我们根据从 [45] 获取的数据，计算了2013年至2020年的小时平均值。由于八年的数据不足以评估长期关系，因此从 [50]获取了2001年和2012年的小时平均值。此外，我们从 [51]获取了2000年至2020年乌克兰的宏观经济因素。为选择最合适的长期模型，我们考虑了2001年至2018年范围内共18个独立的宏观经济因素序列，并按照 [52, 11]所述，对所有可能的组合计算了多元线性回归模型（LM）。未纳入2019年和2020年的数据，以便将其用于样本外拟合检验。对于18个预测变量值，这将产生 2^{18} 个线性模型。我们根据AICc对这些模型进行排序，并对其中最佳的1000个模型进行k折（k=5）交叉验证，以避免过拟合。将交叉验证结果中的最低均方根误差和平均绝对误差值作为基线，所有超过基线值150%的模型均被舍弃。随后，使用剩余模型预测2019年至2020年的测试集。选择实际值与预测值之间最大距离最小的模型，并对其残差的正态性和多重共线性进行检验。所选长期模型定义如下：

$$\begin{aligned}\bar{D}_L(y) = \beta_{L,1} + \beta_{L,2} GDP_\delta(y) + \beta_{L,3} IND(y) + \beta_{L,4} GRO(y) \\ + \beta_{L,5} SERV(y) + w(y)\end{aligned} \tag{2}$$

其中，$\beta_{L,i}$为回归系数，$i \in \{1,\ldots,5\}$，GDP_δ为年度 GDP 平减指数（%），IND 为按 2015 年不变美元计价的工业增加值占 GDP 比重，GRO 为年度 GDP 增长率（%），$SERV$为按现价美元计价的服务业增加值。最后，$w(y)$ 是均值为零、方差为 σ_w^2 的噪声过程。

小时负荷的年平均值预测值和实际值如图 4a 所示，残差结构如图 4b 所示。除图示方法外，我们还进行了 Shapiro-Wilk 正态性检验；p 值为 0.62，表明误差过程服从正态分布，且$\sigma_w^2 = 341.1$。

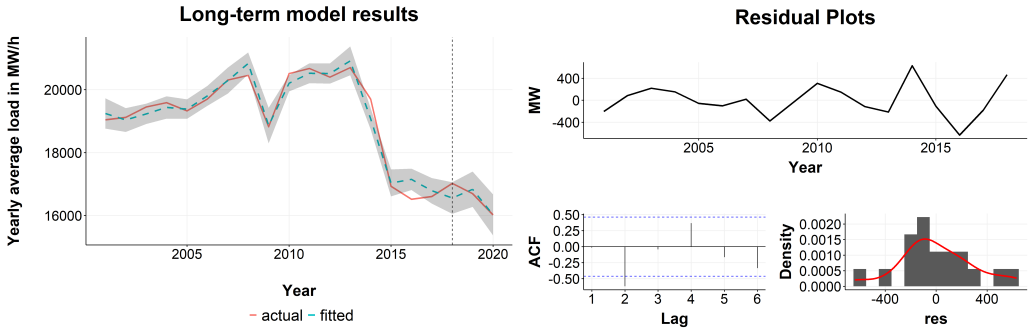

(a) 长期实际值与预测值　　(b) 长期模型的残差

图 4：(a) 长期模型预测值（虚线）与实际值的比较。垂直虚线标示训练集与测试集的分界。灰色区域表示 95% 置信区间。(b) 上方的残差图显示训练集中各年份的残差绝对值；左下图显示残差的自相关函数，右下图显示残差密度分布。

3.2. 中期模型

令 $D_d(t_2,t_1)$ 表示年份 t_1第 $t_2 \in \{1,2,\ldots,365\}$ 天的小时平均值，其定义如下：

$$\bar{D}_d(t_2,t_1) = \frac{1}{24} \sum_{j=1+24(t_2-1)+8760(t_1-1)}^{24t_2+8760(t_1-1)} D_h(j)$$

其中，D_h 为数据集中的给定小时需求。中期需求定义为小时负荷的日平均值与小时负荷的年平均值之差：

$$\bar{D}_M(t_2, t_1) = \bar{D}_d(t_2, t_1) - \bar{D}_L(t_1). \tag{3}$$

减去小时年平均值后，时间序列的长期趋势得到校正。因此， D_M 的年平均值为零。与 Sotiropoulos 等人一样， [39], 我们将中期模型分为线性回归和随机成分:

$$\bar{D}_M(t_2, t_1) = d_M(t_2, t_1) + \xi_M(t_2, t_1) \tag{4}$$

线性回归部分 $d_M(t_2, t_1)$ 指趋势和季节性成分，而随机模型 $\xi_M(t_2, t_1)$ 则拟合剩余部分。这里假设，线性回归部分的残差仍包含相关信息，其内在结构仍可通过 ARIMA 或机器学习方法捕捉。

在中期模型中，以日为粒度，电力需求主要受温度、季节和星期几影响。由于负荷与温度之间存在非线性关系，因此按照 [53] 的介绍并在 [54, 11]中采用的方法，将每日平均温度值转换为采暖日和制冷日。采暖日定义为$HD(t_2, t_1) = max\{T_{ref} - T(t_2, t_1)\ 0\}$，制冷日定义为 $CD(t_2, t_1) = max\{T(t_2, t_1) - T_{ref}, 0\}$。其中， T为温度。 T_{ref} =的取值18.33来自 [11]。模型中纳入了截至三次多项式的HD 和CD值项。为考虑连续高温或低温天气，将滞后一天和两天的HD、CD 及温度值作为滞后变量加入预测变量中。为捕捉季节性负荷模式并避免完全共线性，构造了前十一个月份（ToM）的哑变量。同样，为获得每周季节性，我们为前六个工作日（ToD）中的每一天分别设置一个哑变量，并为节假日设置另一个哑变量（H）。中期线性回归模型总共考虑了32 个预测变量。这将产生 2^{32} 种可能的线性模型组合。为降低计算量，在选择最佳模型时，我们排除了每个工作日的哑变量（共 6个），并针对剩余的 2^{26} 种可能组合，根据最小 AICc 计算最佳线性模型。随后，逐步加入被排除的预测变量，以获得拟合效果最佳的模型。最终的线性回归模型定义如下:

$$
\begin{aligned}
\bar{d}_M(t_2,t_1) = {} & \beta_{M,1} + \beta_{M,2}T(t_2,t_1) + \beta_{M,3}T_{i-2}(t_2,t_1) + \beta_{M,4}CD^2(t_2,t_1) \\
& + \beta_{M,5}CD^3(t_2,t_1) + \beta_{M,6}CD_{i-2}(t_2,t_1) + \beta_{M,7}HD(t_2,t_1) \\
& + \beta_{M,8}HD^2(t_2,t_1) + \beta_{M,9}HD^3(t_2,t_1) + \beta_{M,10}HD_{i-2}(t_2,t_1) \\
& + \beta_{M,11}H(t_2,t_1) + \sum_{l=1}^{6} \beta_{M,l}\ ToD_l(t_2,t_1) \\
& + \sum_{k\in\{3,4,6,8,10\}} \beta_{M,k}\ ToM_k(t_2,t_1)
\end{aligned}
\tag{5}
$$

其中，$\beta_{M,j}$ 是 $j \in \{1,\ldots,11\}$的截距项和与温度相关的回归变量的回归系数；$\beta_{M,l}$是 $l \in \{1,\ldots,6\}$各类日期的回归系数；$\beta_{M,k}$是相应月份的五个回归系数。

图 5 显示了中期模型（定义见公式 5）的预测值和实际值。残差近似服从正态分布，均值为零，标准差为 590 MW。然而，图 5b 中的自相关函数（ACF）图显示存在显著的自相关。因此，我们采用随机 ARIMA 模型和机器学习方法来预测残差中不同于白噪声的剩余潜在结构。

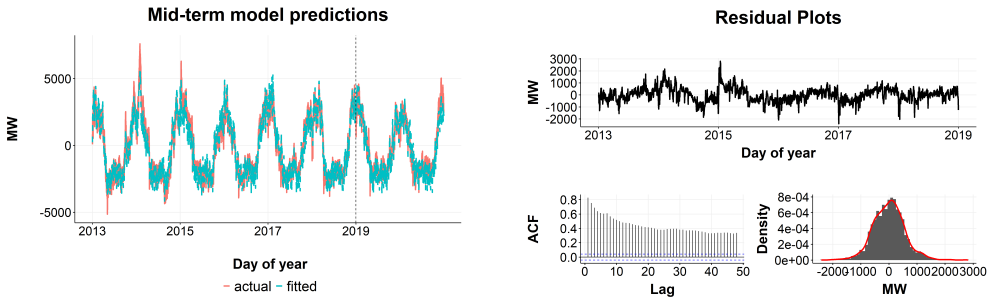

（a）线性回归中期模型的预测值和实际值。（b）线性回归中期模型的残差分析。

图5：（a）中期模型预测值（蓝色虚线）与实际值的对比。竖直虚线标示训练集与测试集的分界。（b）上方的残差图显示训练集中每天的残差值；左下图显示残差的自相关函数，右下图显示残差的密度分布。

3.2.1. 中期随机 *AR* 分量

中期模型的自回归部分拟合线性回归分量的残差。我们进行了增广迪基-富勒（ADF）检验和克维亚特科夫斯基-菲利普斯-施密特-申（KPSS）检验，结果表明残差序列非平稳。因此，我们通过差分使其达到平稳，并采用 ARIMA 模型方法。典型的 ARIMA(p,d,q) 模型可表示为：

$$\varphi_p(B)(1-B)^d z_t = \theta_q(B)\varepsilon_t \tag{6}$$

其中，z_t 表示时间 t处的非平稳时间序列，ε_t 为白噪声，d 为差分阶数，B 为后移算子，定义为 $Bz_t = z_{t-1}$，φ_p（B）为自回归算子，定义为：

$$\varphi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \cdots - \varphi_p B^p. \tag{7}$$

此外，θ_q(B) 是定义如下的移动平均算子：

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q \tag{8}$$

为确定合适的模型，采用了以下方法，同时考虑了对其他数据集的可复现性以及自定义自动化的可能性。首先，确定使序列变为平稳序列所需的最低差分阶数。这通过使用$auto.arima$函数，在 R $forecast$ 程序包 [55, 56] 中实现。随后，使用 ACF 和偏自相关函数（PACF）对差分后的时间序列进行检验，以分别确定仍存在显著自相关时p 和 q 的最高阶数。然后，将所得数值作为逐步网格搜索的上限，p和 q的取值分别从1开始变化。p 和 q值的上界各增加 2，以便检查复杂度略高于由 ACF 和 PACF 确定阶数的模型。$auto.arimafunction$ 给出的 d 值保持不变，因为它已经是实现平稳性所需的最优差分阶数。

随后使用条件平方和估计法计算所有指定 p、d 和 q 值对应的 ARIMA模型，以获得初始值；之后再通过最大似然估计法估计相应的 AR 和 MA 系数。

大多数ARIMA模型在2013年至2018年的训练集中表现出非常高的预测准确率，但在测试集中的预测准确率明显较低

2019年和2020年。因此，网格搜索设定为选择在测试集上预测准确率最高的ARIMA模型，而不是选择在训练集上AICc最低的模型。

确定最佳ARIMA模型后，通过加入外生回归变量进行验证，以确定是否可以进一步提高预测准确率。为此，针对中期模型中使用的每个预测变量，分别采用多次Kolmogorow-Smirnow检验（KS）和Levene检验，对组内方差的一致性和组间方差的同质性进行检验。在独立变量6月、8月和10月中，发现中期残差存在显著的组内一致性偏差。因此，这3个预测变量被纳入ARIMA模型，作为外部回归变量。

通过上述讨论的方法，确定带有外部回归变量的 ARIMA(30,1,25) 是描述中期确定性模型所留下残差的最佳拟合模型。图 6 展示了所选 ARIMA 模型对 2013年-2018年的训练集进行的残差预测，以及相应的残差。从图 6a 可以看出，所选 ARIMA 能够很好地描述该残差时间序列，而图 6b 中的 ACF 图显示，残差之间已不存在显著的自相关。

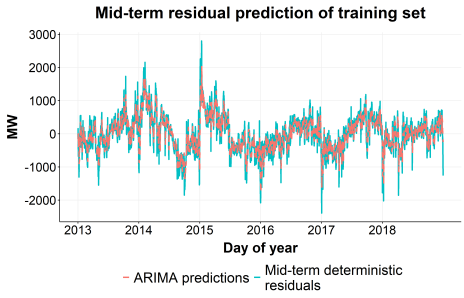

(a) 中期确定性残差与预测值
通过ARIMA建模得到的残差值。

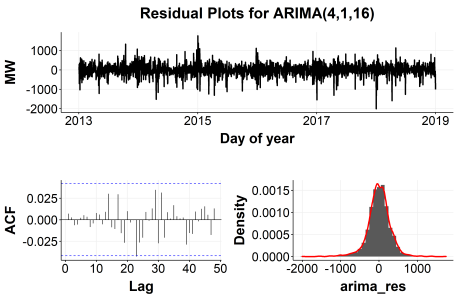

(b) ARIMA模型预测的残差

图 6：ARIMA 样本内预测及残差结构。

2019年和2020年的测试集预测结果如图7所示。可以看出，线性回归 d_M 中期模型的残差均处于ARIMA预测的80%置信区间内。数值低于95%置信区间的唯一时间点是2020年4月。这是由于能源消耗在

2019冠状病毒病大流行的早期阶段。根据图7可以清楚地看出，ARIMA模型能够为中期回归模型的预测误差幅度提供有用信息，但缺乏准确预测未来时间范围内实际值的能力，而这些时间范围超出了模型的滞后阶数。

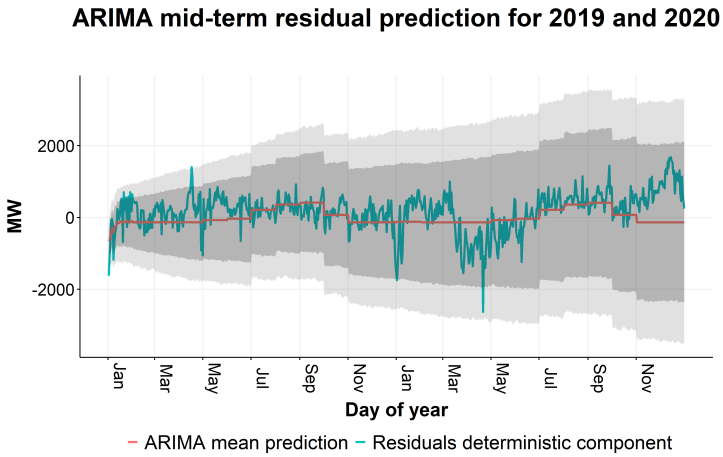

图7：2019年和2020年的样本外ARIMA中期残差预测。深灰色区域表示80%的置信区间，浅灰色区域表示95%的置信区间。

在较短的预测时间范围内，例如预测未来两周或一个月，该方法将大幅提高预测准确度；而对于较长的时间范围，预计只能带来小幅改善。这是因为，当预测时间范围超过模型的滞后阶数后，预测将基于先前的预测值，且未经验证。因此，只有预测均值可以被可靠地采用。为克服这一局限，并检验残差时间序列能否进一步通过非线性方法进行拟合，我们训练并测试了一个机器学习LSTM模型。

3.2.2. 中期*LSTM*组件

长短期记忆（LSTM）是由 [57] 开发的一种循环神经网络（RNN）。这类神经网络具有特殊的反馈连接，可以存储近期输入的信息。基础 RNN 在长期时间依赖关系上存在梯度消失问题。要

为解决这一问题，长短期记忆网络由 Schmidhuber和Hochreiter 于 1997 [57]提出。长短期记忆网络的总体架构由一个记忆单元组成，其中可以存储信息，并通过三个不同的门与一个神经元相连接：遗忘门、输入门和输出门。遗忘门根据公式 9 控制从上一状态（c_{t-1}）存储到单元中的信息。输入门决定当前状态所使用的信息（公式 10），而输出门控制输出所需的信息（公式 11）：

$$f_t = \sigma(W_f * [h_{t-1}, X_t] + b_f) \tag{9}$$

$$i_t = \sigma(W_i * [h_{t-1}, X_t] + b_i) \tag{10}$$

$$o_t = \sigma(W_o * [h_{t-1}, X_t] + b_o) \tag{11}$$

其中， W_x 和 B_x 表示神经元的不同权重和偏置，σ 是 sigmoid激活函数， h_{t-1} 是 $t-1$ 时间步的隐藏层输出，而 X_t 是每个时间步的输入向量。当前隐藏状态 c_t 描述如下：

$$\bar{c}_t = tanh(W_c * [h_{t-1}, X_t] + b_c) \tag{12}$$

$$c_t = ft * c_{t-1} + i_t * \bar{c}_t \tag{13}$$

其中， W_c 和 b_c 表示当前门的权重和偏置，双曲正切激活函数记为 $tanh$。LSTM层的输出为：

$$h_t = o_t * tanh(c_t) \tag{14}$$

本研究将序列到序列（S2S 或 Seq2Seq）算法作为 LSTM模型的输入向量。Seq2Seq 模型由两部分组成：编码器和解码器（图 8）。

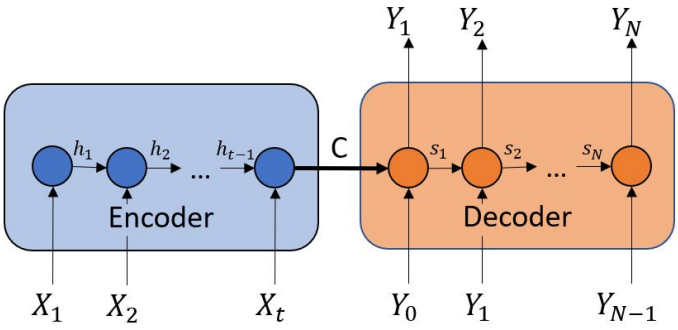

图 8：序列到序列模型的结构

对于输入序列 $X = [X_1, X_2, ..., X_t]^T$，本研究使用的长短期记忆网络会将数据的表示编码到层 $h = [h_1, h_2, ..., h_t]^T$的隐藏状态中。具体做法是利用神经元 h_{t-1}的前一隐藏状态、当前输入 X_t 以及层的循环计算 $f(\cdot)$，计算出隐藏状态 h_t：

$$h_t = f(h_{t-1}, X_t) \tag{15}$$

上下文向量 C（即最后一个时间步的隐藏状态）随后被馈送至解码器，以通过以下方式预测未来值：

$$y_t = g(s_{t-1}, C) \tag{16}$$

其中，s 表示隐藏层的状态，$g(\cdot)$表示层的激活函数，y_t 表示预测值。

更长的输入序列传入编码器后，可能会导致解码器难以从上下文向量中识别有价值的信息。这是因为所提供的数据表示类似于单个向量。注意力机制使解码器能够灵活地关注最重要的部分。本研究使用的机制是由 [58] 开发的Luong 注意力机制。为此，通过比较解码器 h_t 与编码器 h_s 的所有隐藏状态来计算对齐向量 a_t：

$$a_{ti} = align(h_t, s_t) = \frac{exp(S(h_t, h_s))}{\sum_k S(h_t, h_{sk})} \tag{17}$$

对于评分函数 $S(h_t,\ h_{sk})$，Luong 等人提出了三种不同的函数：

$$S(h_t, h_{sk}) \begin{cases} h_t^T h_s & dot \\ h_t^T W_a h_s & general \\ v_a^T tanh(Wa[h_t; h_s]) & concat \end{cases} \tag{18}$$

将 v 作为可训练参数，可以在神经网络训练阶段进行学习。本研究采用 TensorFlow/Keras 对注意力机制的实现[59]。

表 1：优化后的 Seq2Seq 模型参数

参数设置	**层 1**	**层 2**
层类型	LSTM	LSTM
节点	118	82
激活	Sigmoid	Relu
Dropout	0.385	0.08
输出大小	1	
优化器	ADAM	
训练轮数	300	
批次大小	64	
学习率	0.00074	
输入长度	584	
输出长度	730	

LSTM模型方法的结果如图9所示。与图7所示的ARIMA预测相比，预测出的残差时间序列动态性更强，捕捉到了部分残差结构。将预测的残差加到线性回归中期模型的预测值中，可使残差总和减少约13.2 %。

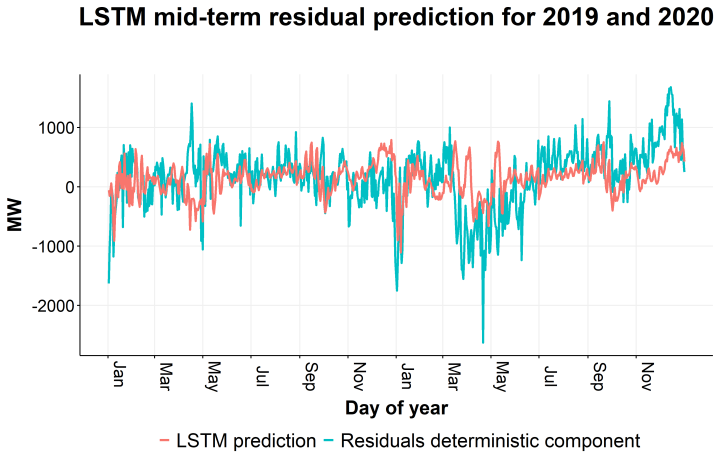

图9：线性回归中期模型的残差以及2019年和2020年的样本外长短期记忆网络中期残差预测。

3.2.3. 混合中期模型

测试并评估了三种不同的混合模型：添加 ARIMA 残差预测的线性回归模型（LM）、添加长短期记忆网络残差预测的 LM，以及结合添加长短期记忆网络和 ARIMA 残差预测的 LM。表 2 展示了所选误差指标以及每种方法对总体残差和的影响。对于残差和，我们计算了所有时间步的全部残差之和，并将 LM 预测所得的值作为基准（100 %）。随后，我们评估了相应混合预测的总体残差和是否更小（低于 100 %）或更大。添加长短期记忆网络预测的 LM 取得了最佳结果。因此，公式 4 中定义的完整中期模型是公式 5 中定义的 $d_M(t_2,\ t_1)$ 与第 3.2.2 节中定义的长短期记忆网络 RNN 模型之和。

表 2：2019年和2020年测试集的中期负荷预测中，均方根误差（RMSE）、平均绝对误差（MAE）、平均绝对缩放误差（MASE）及其对残差平方和的影响的比较。

	均方根误差 [MW]	平均绝对误差 [MW]	平均绝对缩放误差	残差和 %
LM	552.8	430.8	0.495	100
LM+ARIMA	533.4	399.6	0.459	92.8
LM+长短期记忆网络	500.6	374.0	0.429	86.8
LM+ARIMA+长短期记忆网络	504.0	382.9	0.440	88.9

完整的中期预测结果如图10所示，其中图10a展示了完整的预测结果，图10b则更详细地显示了2019年和2020年的测试集预测结果。

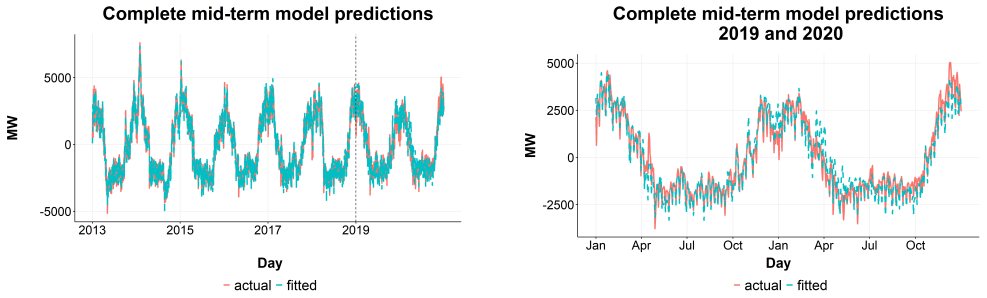

(a) (b)

图 10：整个数据集的完整中期需求预测 (a) 和测试集的需求预测 (b)。(a) 中的垂直虚线标示训练集与测试集的分界。

3.3. 短期模型

短期模型定义为年平均值与日均值之差，再加上小时负荷：

$$\bar{D}_s(t_3, t_2, t_1) = D_h(8760(t_1 - 1) + 24(t_2 - 1) + t_3) - \bar{D}_M(t_2, t_1) - \bar{D}_L(t_1)$$

其中 $t_3 \in \{1, 2, \ldots 24\}$。从用量值中减去年度和每日小时平均值后，便保留了特定时段的负荷模式

日负荷模式仍然存在。与中期模型类似，短期模型定义为线性回归模型（$d_S(t_3,t_2,t_1)$）与随机部分（$\xi_S(t_3,t_2,t_1)$）之和：

$$\bar{D}_S(t_3,t_2,t_1) = d_S(t_3,t_2,t_1) + \xi_S(t_3,t_2,t_1) \tag{19}$$

日负荷曲线主要受季节影响，即月份和日期类型。中期模型中已包含用于表示这些特征的虚拟变量。由于所有子模型都会合并成一个最终的加性模型，因此不能再将这些变量纳入短期模型。为考虑这些影响，分别针对日期类型与月份的每一种组合拟合不同的回归模型，之后将其相加以预测完整的时间范围。线性回归部分中纳入的唯一预测变量，是表示一天中各小时的虚拟变量 ToH（0/1）。由于所有虚拟变量都是二元变量，因此线性回归变量中只纳入 23 个小时，而非 24 个。由此，线性回归短期模型定义如下：

$$\hat{d}_S(t_3,t_2,t_1) = \sum_{m=1}^{12}\sum_{d=1}^{7}\left(\beta_{S,0,m,d} + \sum_{h=1}^{23}\beta_{S,h,m,d}\ ToH_h(t_3,t_2,t_1)\right) \tag{20}$$

其中，$\beta_{S,0,m,d}$ 表示每个模型的截距，而 $\beta_{S,h,m,d}$ 分别表示每个月份（m）和工作日（d）组合对应的二十三个回归系数。

鉴于方程 20 中定义的线性回归成分的性质，显然残差会因月份和日期不同而呈现不同特征。因此，针对每个月的残差分别拟合一个不同的 AR 模型。12 个相应的 AR 模型采用与第 3.2.1 节所述类似的方法确定。由于所有 12 个月的残差时间序列均为平稳序列，因此采用自回归移动平均模型，而非 ARIMA模型。ACF 的结果表明，残差呈现季节性自相关。由于一天具有 24 小时的周期性，最初采用了季节周期为滞后 24 阶的季节性自回归移动平均模型。但这种方法未能完全消除残差中的自相关。因此，确定使自相关不再显著的最低 p 阶和 q 阶，并据此计算相应的自回归移动平均模型。对大多数月份而言，最终得到的是 ARMA(27,26)模型。与中期线性回归残差不同，短期模型残差呈现出

更明显的重复模式。因此，只要预测时域仍处于模型的滞后阶数范围内，自回归移动平均模型的预测结果也可用于预测该月内所有后续日期。由于这种方法效果非常好，因此没有必要再针对短期残差采用另一种长短期记忆网络方法。

图 11a展示了2016年九月某一周的样本内预测，而图 11b 展示了2019年同一周的样本外预测。仔细考察图 11 可以发现，季节性日

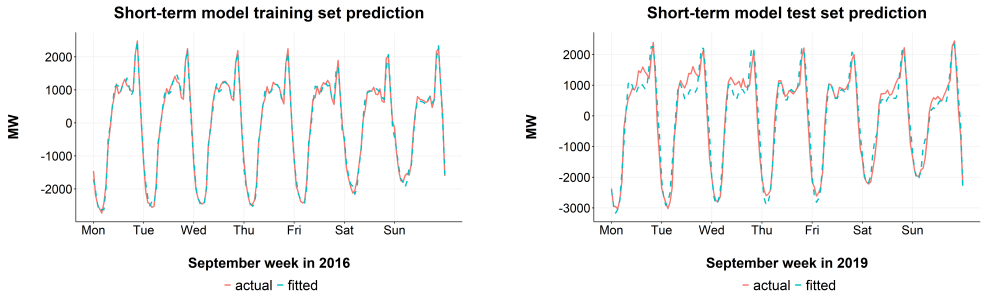

(a) 样本内短期预测。　　（b）样本外短期预测

图 11：训练集和测试集中的某个样本周的短期负荷模式及模型预测。

负荷模式在2016年至2019年期间没有发生太大变化，并且我们的CST方法能够很好地描述它。

4. 预测结果

我们结合并评估了加法方程1中定义的所有模型组件，以预测2019年和2020年测试时段的电力需求。表3展示了相应预测时域的四种不同误差参数（均方根误差、平均绝对百分比误差、平均绝对误差、平均绝对缩放误差）。此外，还报告了包含2013年至2018年训练集数值的预测结果，以便同时概览样本内的准确度。均方根误差和平均绝对误差以兆瓦（MW）为单位报告，2019年和2020年的每小时需求值范围为10905 MW/h至23642 MW/h。与2019年相比，2020年预测的平均绝对百分比误差有所上升，这很可能是由于COVID-19全球大流行的开始所致。尽管2020年的预测准确度略有下降，但约3.17%的平均绝对百分比误差仍然是一个非常好的结果，尤其是对于包含17520个预测小时值的预测时域而言。

表 3：随机中期残差预测的比较。

	均方根误差 [MW]	平均绝对百分比误差 [%]	平均绝对误差 [MW]	平均绝对缩放误差
2013年至2020年	599.1	2.78	473.2	0.372
预测2019年和2020年	682.4	3.17	516.5	0.457
预测2019年	619.8	2.79	467.8	0.473
预测 2020年	739.6	3.56	565.3	0.444

图 12 展示了 2019年和 2020年完整的模型预测值和实际值。图 13 分别展示了 2019年和 2020年年中各一周的样本，以便更详细地呈现预测需求和实际需求的结构，以及典型的误差情况。从图 13a 可以看出，第一个星期一（17.06.）白天时段的需求异常偏低，预测未能很好地捕捉到这一变化；此外，预测还低估了星期五（28.06.）夜间至星期六（29.06.）的负荷。除此之外，该时段的预测需求结构似乎与实际需求相当吻合。2020年相同的周（图 13b）呈现出更稳定的结构，预测在中午时段略有高估，但其他时段的预测效果相当不错。

x

本文提出了一种用于全国电力需求预测的新型混合模型。输入数据包括乌克兰2013年至2020年的小时电力需求、宏观经济变量和温度。所提出的方法首先根据时间尺度将数据分为三类：涵盖年度预测的长期模型、预测未来数日的中期模型，以及以小时分辨率进行预测的短期模型。长期模型通过基于宏观经济和人口统计变量的线性回归模型得到了良好刻画。中期模型结合温度和日历回归变量来描述潜在结构，并采用ARIMA模型和基于模式的LSTM“黑箱”方法来描述残差。最后，短期部分通过基于日历变量的线性回归变量以及不同的自回归移动平均模型得到了良好刻画

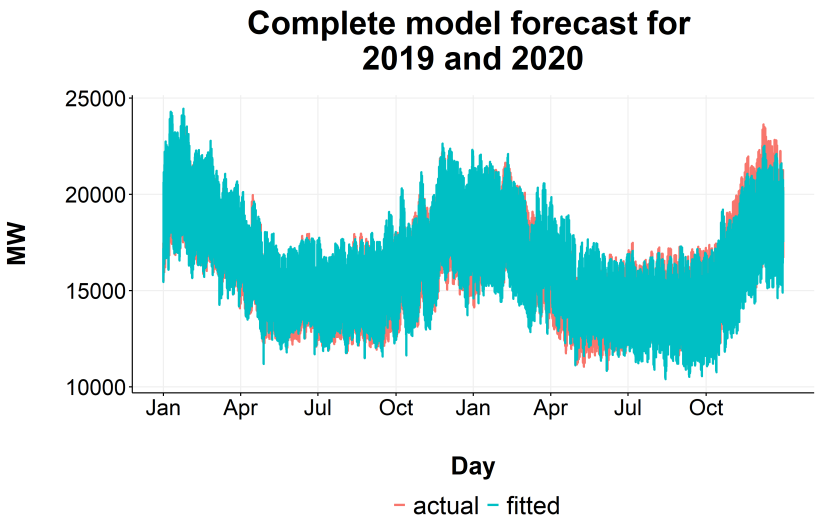

图 12：2019年和 2020年测试期间乌克兰每小时需求的完整预测。

以描述残差。线性回归模型和ARIMA模型在R [60]中计算得出。LSTM模型使用Python [61]编写。两套代码均已作为开源软件发布于 [62]。

所提出的混合算法主要有两大优势。一方面，它通过经典统计回归模型描述数据的内在结构及其关系，从而有助于了解在不同时间范围内影响电力需求的当前和未来驱动因素。了解具有影响力的外部因素，有助于决策者在未来内在结构发生变化时及时作出应对。另一方面，该算法结合了 ARIMA 和长短期记忆网络方法来修正残差并提高预测准确率。该模型的主要缺点是，进行未来预测需要高分辨率的宏观经济数据预测。此外，还需要将历史天气数据外推至未来。

未来研究应考虑在其他发展中国家和工业化国家复制并复用这一算法。为便于完成这项工作，制定该方法时已考虑提供自动化选项。所有必要数据均可通过自动 API 请求获取，模型计算和评估也可实现全自动化。

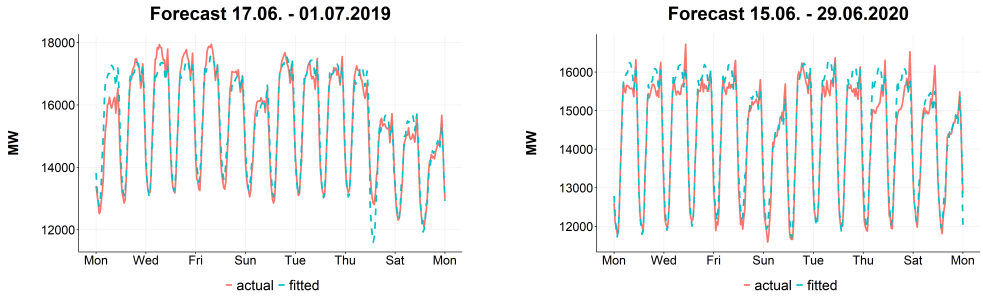

（a）2019年6月的两个样本周。 (b) 2020年6月的两个样本周。

图13：从周一开始的2019年6月和2020年6月两个示例周的预测需求与实际需求。

参考文献

[1] S.-H. Yoo，电力消费与经济增长：来自韩国的证据，《能源政策》33 (2005) 1627–1632。[2] G. Altinay，E. Karagol，电力消费与经济增长：来自土耳其的证据，《能源经济学》27 (2005) 849–856。[3] A. Shiu，P.-L. Lam，中国的电力消费与经济增长，《能源政策》32 (2004) 47–54。[4]B. Hobbs，S. Jitprapaikulsarn，S. Konda，V. Chankong，K. Loparo，D. Maratukulam，改进负荷预测对机组组合价值的分析，《IEEE 电力系统汇刊》14 (1999) 1342–1348。[5] A. A. Mamun，M. Sohel，N. Mohammad，M. S. Haque Sunny，D. R. Dipta，E. Hossain，单一与混合预测模型负荷预测技术综述，《IEEE Access》8 (2020年) 134911–134939。[6] D. Bunn，E. Farmer，电力负荷预测的经济与运行背景，《电力负荷预测比较模型》(1985) 3–11。[7] J. Carvallo，P. H.，Sanstad，G. A.，电力公用事业综合资源规划中的长期负荷预测准确度，《能源政策》119 (2018年) 410–422。

[8] K. Lindberg、P. Seljom、H. Madsen、D.Fischer、M.Korp˚as,《长期电力负荷预测：当前与未来趋势》，《公用事业政策》58（2019年）102–119。[9] H.Malik、N. Fatema、I. Atif,《用于状态监测的智能数据分析》，AcademicPress，2021年。[10] R. K. Agrawal、F.Muchahary、M. M. Tripathi,《基于长短期记忆网络的长期负荷预测与逐小时预测》，载于：2018年IEEE 德州电力与能源会议（TPEC），第1–6页。[11] A. Pielow、R.Sioshansi、M. C. Roberts,《利用长期增长率和消费者价格弹性对商业和工业部门的短期电力需求进行建模》，《能源》46（2012）533–540。[12] E. Yukseltan、A.Yucekaya、A. H.Bilge,《土耳其电力需求预测：周期性变化与需求细分建模》，《应用能源》193（2017）287–296。[13] E.Vivas、H. Allende-Cid、R.Salas,《对电力预测中统计和机器学习方法及其平均绝对百分比误差得分的系统综述》，《熵》22（2020年）。[14] D. Angelopoulos、J. E. Psarras、Y. Siskos,《通过序数回归分析进行长期电力需求预测：希腊案例》，2017年 IEEE 曼彻斯特电力技术会议（2017年）1–6。[15] G. Tsekouras、E. Dialynas、N. Hatziargyriou、S. Kavatza,《电力系统中期能源预测的非线性多变量回归模型》，《电力系统研究》77（2007年）1560–1568。[16] L. Duan、D. Niu、Z. Gu,《采用多层递归回归分析的长期和中期电力负荷预测》，载于：2008年第二届智能信息技术应用国际研讨会论文集——第01卷，IITA 2008，IEEE计算机学会，美国，2008年，第514–518页。[17] F. Chui、A. Elkamel、R. Surit、E. Croiset、P. D.,《利用经济、人口和气候变量进行电力系统规划的长期电力需求预测》，《欧洲工业工程杂志》3（2009年）277–304。

[18] S. A. Sarkodie，利用 ARIMA 预测加纳 2030 年电力消费，《能源来源，B 部分：经济学、规划与政策》12（2017）936–944。[19] Y. Wang、J. Wang、G. Zhao、Y. Dong，将残差修正方法应用于季节性 ARIMA 电力需求预测：以中国为例，《能源政策》48（2012）284–294。专题：可持续发展前沿。.. .[20] U. Filik、O. Gerek、M. Kurban，一种用于长期电能需求逐小时预测的新型建模方法，《能源转换与管理》52（2011）199–211。[21] C. Nichiforov、I. Stamatescu、I. F˘ag˘ar˘a¸san、G. Stamatescu，使用 ARIMA 和神经网络模型预测能源消费，载于：2017 年第五届国际电气与电子工程研讨会（ISEEE），第 1–4 页。[22] L. J. Soares 、 M. C. Medeiros，短期电力负荷建模与预测：方法比较及其在巴西数据中的应用，《国际预测杂志》24（2008）630–644。能源预测。[23] E. A. Feinberg、D. Genethliou，负荷预测，载于：J. H. Chow、F. F. Wu、J. Momoh（编），《重组电力系统应用数学》，第 1 卷，Springer，波士顿，2005 年，第 269–285 页。[24]A. Mosavi、M. Salimi、S. Faizollahzadeh Ardabili、T. Rabczuk、S. Shamshirband、A. R. Varkonyi-Koczy，能源系统机器学习模型的最新进展：系统综述，《能源》12（2019）。[25] M. S. AL-Musaylh、R. C. Deo、J. F. Adamowski、Y. Li，利用融合地面气候数据与 ECMWF 再分析大气预测因子的机器学习方法预测澳大利亚昆士兰东南部短期电力需求，《可再生与可持续能源评论》113（2019）109293。[26] G. Tsekouras、N. Hatziargyriou、E. Dialynas，用于年度中期能源预测的优化自适应神经网络，《IEEE 电力系统汇刊》21（2006）385–391。

[27] A. Azadeh, S. Ghaderi, M. Sheikhalishahi, 《利用人工神经网络优化伊朗电力市场的短期负荷预测》, 《优化工程》15（2014年）485–508。[28] C. Hamza¸cebi, H. Es, R. C¸akmak, 《利用季节性人工神经网络预测土耳其月度电力需求》, 《神经计算与应用》31（2019年）2217–2231。[29] S. Saravanan, S. Kannan, C. Thangaraj, 《利用人工神经网络预测印度电力需求》, IEEE工程、科学与管理进展国际会议（I CAESM - 2012）（2012年）79–83。[30] J. Ma, A. Oppong, K. N. Acheampong, L. A. Abruquah, 《在零假设条件下预测可再生能源消耗》, 《可持续发展》10（2018年）。[31] Y. Jung, J. Jung, B. Kim, S. Han, 《用于建模太阳能光伏设施长期电力预测时间模式的长短期记忆循环神经网络：韩国案例研究》, 《清洁生产杂志》250（2020年）119476。[32] D. Benaouda, F. Murtagh, J.-L. Starck, O. Renaud, 《基于小波的电力负荷预测非线性多尺度分解模型》, 《神经计算》70（2006年）139–154。《神经网络》。[33] S. Makridakis, E. Spiliotis, A. V., 《统计与机器学习预测方法：问题与改进方向》, 《PLoS ONE》13（2018年）。[34] L. Ghods, M. Kalantar, 《长期电力负荷需求预测方法：全面研究》, IEEE工业技术国际会议论文集（2008年）2–5。[35] F. Chuang, C.-Y. Hung, C. Chang, K. Kuo, 《应用 ARIMA 和人工神经网络模型预测台湾能源消耗》, 《传感器快报》11（2013年）2333–2340。[36] K. Lindberg, D. G. Fischer, D., I. Sartori, 《零能耗建筑的成本最优能源系统设计及其对电网的影响：德国一栋多户住宅的案例研究》, 《能源与建筑》127（2016年）830–845。

[37] B. K.G., 《电力需求预测的全新多时间尺度建模：从短期到中期时域》，《电力系统研究》142（2017年）58–73。[38] F. M. Andersen, H. V. Larsen, T. K. Boomsma, 《每小时电力负荷的长期预测：消费特征识别与客户细分》，《能源转换与管理》68（2013年）244–252。[39] E. Sotiropoulos, Y. He, M. Hildmann, G. Andersson, 《用于远期合约定价的电力负荷建模》，载于：2013年 IEEE电力与能源学会总会，IEEE，第1–5页。[40] L. M. de Menezes, D. W. Bunn, J. W. Taylor, 《组合预测使用指南综述》，《欧洲运筹学杂志》120（2000年）190–204。[41] R. T. Clemen, 《组合预测：综述及附注书目》，《国际预测杂志》5（1989年）559–583。[42] G. W. Chang, H. J. Lu, L. Y. Hsu, Y. Y. Chen, 《风速和风力发电预测的混合模型》，载于：2016年 IEEE电力与能源学会总会（PESGM），第1–5页。[43] J. Wang, J. Wang, Y. Li, S. Zhu, J. Zhao, 《将小波去噪应用于短期负荷预测组合模型的技术》，《国际电力与能源系统杂志》62（2014年）816–824。[44] A. Laouafi, M. Mordjaoui, S. Haddad, T. E. Boukelia, A. Ganouche, 《基于有效预测组合方法的在线电力需求预测》，《电力系统研究》148（2017年）35–47。[45]乌克兰国家电力公司, 《乌克兰每小时电力平衡》，
https://data.gov.ua/dataset/31199018-e15e-4e87-bf5e-2a4293151f5c/resource/0cf8c840-7d54-4dba-86c1-8802884e7469，2020年。访问日期：2019年11月2日。[46] K. W. Lukas Feldhaus, G. Zachmann, 《乌克兰接入欧洲电网》，德国国际与安全事务研究所（2021年）。

[47]乌克兰国家统计局文件发布，
https://ukrstat.org/en/operativ/operativ2007/ds/kn/kn_e/arh_kn07_e.html，2019年。访问日期：10.02.19。[48] L. Ginsborg、D. R.，《后冲突时期的顿巴斯应采用何种经济模式？经济措施如何助力摆脱负面情景》，https://core.ac.uk/reader/219383500，2019年。[49] 全球建模与同化办公室（GMAO）、戈达德地球科学数据与信息服务中心（GES DISC），MERRA-2 statD 2d slv Nx 2d，每日汇总统计数据，2015年。访问日期：2021年10月7日，doi:10.5067/9SC1VNTWGWV3。[50] BP《全球能源统计年鉴》，乌克兰发电量，https://ourworldindata.org/energy/country/ukraine，2020年。1–232。[51] 世界银行，《世界发展指标》，2020年。数据取自《世界发展指标》，http://data.worldbank.org/data-catalog/world-development-indicators。[52] H. A. Amarawickrama、L. C. Hunt，《斯里兰卡电力需求：时间序列分析》，《能源》33（2008）724–739。[53] K. Train、P. Ignelzi、R. Engle、C. Granger、R. Ramanathan，《电力销售模型中的计费周期与天气变量》，《能源》9（1984）1041–1047。[54] A. Pardo、V. Meneu、E. Valor，《温度与季节性对西班牙电力负荷的影响》，《能源经济学》24（2002）55–70。[55] R. J. Hyndman、Y. Khandakar，《自动时间序列预测：R 的 forecast 软件包》，《统计软件杂志》26（2008）1–22。[56] R. Hyndman、G. Athanasopoulos、C. Bergmeir、G. Caceres、L. Chhay、M. O'Hara-Wild、F. Petropoulos、S. Razbash、E. Wang、F. Yasmeen，《forecast：时间序列与线性模型预测函数》，2021年。R 软件包版本 8.14。[57] S. Hochreiter、J. Schmidhuber，《长短期记忆》，《神经计算》9（1997）1735–1780。

[58] T. Luong、H. Pham、C. D. Manning，《基于注意力的神经机器翻译的有效方法》，载于：2015年自然语言处理经验方法会议论文集，计算语言学协会，葡萄牙里斯本，2015年，第1412–1421页。[59] M. Abadi、A. Agarwal、P. Barham、E. Brevdo、Z. Chen、C. Citro、G. S. Corrado、A. Davis、J. Dean、M. Devin、S. Ghemawat、I. Goodfellow、A. Harp、G. Irving、M. Isard、Y. Jia、R. Jozefowicz、L. Kaiser、M. Kud-lur、J. Levenberg、D. Man´e、R. Monga、S. Moore、D. Murray、C. Olah、M. Schuster、J. Shlens、B. Steiner、I. Sutskever、K. Talwar、P. Tucker、V. Vanhoucke、V. Vasudevan、F. Vi´egas、O. Vinyals、P. Warden、M. Wat-tenberg、M. Wicke、Y. Yu、X. Zheng，《TensorFlow：异构系统上的大规模机器学习》，2015年。软件可从 tensorflow.org 获取。[60] R 核心团队，《R：统计计算语言与环境》，R 统计计算基金会，奥地利维也纳，2022年。[61] G. Van Rossum、F. L. Drake，《Python 3 参考手册》，CreateSpace，美国加利福尼亚州斯科茨谷，2009年。[62] T. Gonz´alez-Grand´on、J. Schwenzer、T. Steens、J. Breuing，《国家电力预测 GitHub 仓库》，2022年。可从 https://github.com/Autarky-Power/National-Electricity-Forecasting获取。