

基于 DDPM 与 HVAE 的多步电力负荷预测方法

陈 萌^{1,2}
CHEN Meng

摘 要

电力负荷预测在电力系统的优化调度和可靠运行中起着关键作用，针对传统单步预测方法在长期预测上的精确度不足问题，文章提出了一种耦合扩散概率模型（denoising diffusion probabilistic model, DDPM）与分层变分自编码器（bidirectional variational auto-encoder, HVAE）的生成式电力负荷预测模型 DHVAE，模型通过对历史电力数据前向加噪，再将加噪数据送入分层变分自编码器中进行特征提取，最终生成对未来电力负荷侧的多步预测。为验证算法的预测准确性，采用湖北某集团的历史电力数据开展预测仿真实验，实验结果表明，DHVAE 可以实现准确的多步电力负荷预测，为电力系统的优化调度提供有效的方法支撑。

关键词

电力负荷预测；去噪扩散概率模型；分层变分自编码器；多步预测；生成式网络

doi: 10.3969/j.issn.1672-9528.2024.11.032

0 引言

电力负荷预测是电力系统高效运行中不可或缺的重要因素，准确的负荷预测能够有效指导电力系统的发电、输电和配电，使电力供应和需求之间保持平衡^[1]。尤其在电力市场化和智能电网的背景下，负荷预测的准确性直接影响到电力市场的稳定性和经济性，精准的预测能够帮助电力公司优化资源配置，降低发电成本，减少不必要的发电和储能，从而提升整体效率，同时电力负荷预测还能帮助识别潜在的电力短缺或过剩情况，避免可能的停电风险和经济损失^[2]。

电力负荷预测的发展大致经历了三个阶段：传统统计方法阶段、机器学习方法阶段和深度学习方法阶段。在传统统计方法阶段，常用的预测模型包括线性回归、移动平均法和自回归积分滑动平均模型^[3-4]，这些方法在处理线性数据和短期预测方面表现良好，但在应对复杂的非线性关系和长时间跨度的数据时效果不佳；随着计算能力的提升和电力数据的暴增，机器学习方法被引入电力负荷预测领域，这一阶段的代表性方法包括支持向量机、随机森林^[5]和人工神经网络^[6]，这些方法能够捕捉数据中的非线性关系，预测精度得到显著提高；在深度学习阶段，卷积神经网络^[7]和长短期记忆网络^[8]以及注意力机制^[9]开始在电力负荷预测中得到了广泛应用，深度学习方法能够有效处理时间序列数据中的长期依赖问题和复杂的非线性关系，大幅度提高了负荷预

测的准确性和效率^[10]。

上述对于负荷预测的研究大多聚焦于单步预测，尽管在短期的预测精度上十分优越，但在长期多步的预测领域中表现欠佳。针对上述情况，本文基于 DDPM^[11]与 HVAE^[12]提出一个生成式的多步电力负荷预测模型。经实例验证，本文提出的生成式电力负荷预测模型 DHVAE 可以有效实现多步电力负荷预测。

1 负荷预测流程

本文算法流程主要由电力数据前向加噪、HVAE 预测数据生成、DSM 预测结果优化三步组成，DHVAE 网络框架如图 1 所示，电力负荷数据的转换过程如图 2 所示。




图 1 DHVAE 网络框架

1. 湖北省水电工程智能视觉监测重点实验室 湖北宜昌 443002
2. 三峡大学计算机与信息学院 湖北宜昌 443000




图2 电力负荷数据转化流程

首先 DDPM 对原始数据进行前向扩散，获得加噪数据 x_t 与 y_t ；接着将 x_t 送入 HVAE 模型中，HVAE 编码器网络学习 x_t 的数据特征分布，采样生成潜在在变量 Z ，解码器网络利用潜在在变量 Z 实现对未来负荷 $\hat{y}$ 的预测；最后应用 DSM 来优化预测结果，通过最小化 $\hat{y}_t$ 与 y 之间的分数匹配损失函数来得最终的预测 $\hat{y}_t$ 。

1.1 扩散概率模型

DDPM 中的前向扩散过程对电力原始数据进行加噪，可以避免电力数据中的噪声干扰。前向扩散过程通常基于马尔科夫链上进行，该链缓慢向数据添加噪声，在足够加噪步数下，数据最后趋近于高斯分布的形态。

输入数据的加噪过程如图3所示。




图3 目标序列前向扩散

在对真实序列 X 的前向扩散中，得到带噪数据 $x_1, x_2, \dots, x_t, \dots, x_T$ ，近似后验 $q(x_t|x_{t-1})$ 的公式为：

$$q(x_t|x_{t-1}) = N(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I) \quad (1)$$

令 $a_t = 1 - \beta_t$ 以及 $\bar{a} = \prod_{s=1}^t a_s$ ，将 x_t 表示为依赖于初始状态的函数，从而使扩散过程的梯度下降优化变得可行， x_t 公式为：

$$x_t = \sqrt{\bar{a}_t} \cdot x_0 + (1 - \bar{a}_t) \delta_x \quad (2)$$

同时对目标序列 y 进行前向扩散，令 $\beta_t^* = \omega \beta_t$ ， $a_t^* = 1 - \beta_t^*$ 以及 $\bar{a}_t^* = \prod_{s=1}^t a_s^*$ 可得到 y_t ，其公式为：

$$y_t = \sqrt{\bar{a}_t^*} \cdot y_0 + (1 - \bar{a}_t^*) \delta_y \quad (3)$$

式中： δ_x 、 δ_y 为 x 、 y 的标准高斯噪声， β_t 是预设的递增噪声方差表。

1.2 分层变分自编码器

HVAE^[13] 作为 DDPM 逆向过程的替代，提取电力负荷数据的特征，生成潜在在变量 Z 与预测分布 $\hat{y}$ 。在 HVAE 中，预测分布 $\hat{y}$ 公式为：

$$p(\hat{y}_t|x_t) = \int p_\theta(Z|x_t)(\hat{y}_t - f(Z))dZ \quad (4)$$

式中： p_θ 表示所有潜在在变量 Z 的汇总数据密度， f 为参数化函数，表示聚合的解码器网络，最终预测结果 $\hat{y}$ 由概率分布 $p(\hat{y}_t|x_t)$ 生成。

通过在真实序列 x 和 y 中同时加入扩散噪声，并将从生成模型中学习到的数据分布与扩散过程相匹配，可以减少由模型带来的生成噪声影响与数据中的固有噪声影响^[14]，其关系公式为：

$$\lim_{\epsilon \rightarrow 0} D_{KL}(q(\epsilon y_t) \| p(\epsilon \hat{y}_t | Z_t)) < D_{KL}(q(\epsilon y) \| p(\epsilon \hat{y})) \quad (5)$$

式中：第一项是扩散序列的噪声分布 $q(\epsilon y_t)$ 与由扩散序列生成的预测噪声分布 $p(\epsilon \hat{y}_t | Z_t)$ 之间的 KL (Kullback-Leibler) 散度，此项 KL 散度数值反映了数据增广后的不确定性；第二项是真实序列中的噪声分布 $q(\epsilon y)$ 与由真实分布生成的噪声分布 $p(\epsilon \hat{y})$ 之间的 KL 散度，此项 KL 散度反映了数据增广前的不确定性。

在这个耦合过程中，其损失函数的目标为最小化其 KL 散度，具体定义公式为：

$$L_{KL} = D_{KL}(q(y_t) \| p_\theta(\hat{y}_t)) \quad (6)$$

式中： $q(y_t)$ 为真实序列 y 在前向扩散后得到的数据分布， $p_\theta(\hat{y}_t)$ 为 HVAE 生成的预测数据分布。

1.3 去噪分数匹配

在 DHVAE 中，前向扩散的反向过程被 HVAE 所替代，此时的预测结果是倾向于 y_t 的数据分布，而最终目的是得到干净的预测数据 $\hat{y}_t$ 。为此采用 DSM 模块优化预测结果，DSM 模块通过对比含噪预测与能量函数的梯度来改善生成效果，使数据接近于“真实”时间序列的低维流形^[15]，DSM 模块的损失函数和最终预测结果公式分别为：

$$L_{DSM,t} = \mathbb{E} q(\hat{y}_t | y) \sigma_t \| y - \hat{y}_t + \nabla_{y_t} E(\hat{y}_t) \|^2 \quad (7)$$

$$\hat{y}_t = \hat{y} - \nabla_{y_t} E(\hat{y}_t) \quad (8)$$

式中：学到的能量函数的梯度 $\nabla_{y_t} E(\hat{y}_t)$ 可以被视为一个重构步骤，它能够从一个受到噪声干扰的 y_t 序列中恢复出理想数据 $\hat{y}_t$ 。

1.4 网络损失函数

本模型通过结合前向扩散过程、HVAE 以及 DSM，旨在实现对未来电力负荷的多步预测，结合公式 (6) (7)，DHVAE 的网络损失函数公式为：

$$L = \alpha L_{MSE} + \beta L_{KL} + \lambda L_{DSM} \quad (9)$$

式中： α 、 β 、 λ 为训练权重，第一项和第二项计算 y_i 和 $\hat{y}_i$ 之间的 MSE 与 KL 散度，最后一项为 DSM 函数损失。

2 实验设置

2.1 数据集选择

本文使用湖北某集团近三年的历史负荷数据及气象数据作为源数据，经预处理后作为电力负荷数据集使用，数据集采样频率为 15 min，特征因素包括历史电力负荷、风速、气温、湿度，共 79 344 条，数据划分为训练集：验证集：测试集 = 7:1:2。为避免不同特征因素之间存在量纲差异，采用了 z-score 方法对电力原始数据实现预处理，z-score 方法公式为：

$$X_s = \frac{X - \mu}{\sigma} \quad (10)$$

式中： X_s 是标准化后的电力特征数据， X 是原始电力特征数据， μ 为原始数据的均值， σ 为原始数据的标准差。

2.2 评价指标

预测模型性能需要适当的评价指标进行评估，文中选择均方误差（mean square error，MSE）和平均绝对误差（mean absolute error，MAE）与平均绝对百分比误差（mean absolute percentage error，MAPE）来对模型性能进行评价，其评价指标数值越小，代表预测精度越高，其计算方法分别为：

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i} \times 100\% \quad (13)$$

式中： n 为所有负荷预测点的总数； y_i 为第 i 时刻负荷的实际值； $\hat{y}_i$ 为第 i 时刻负荷的预测值。

2.3 实验环境及超参数选择

文中实验仿真硬件配置为 Intel Core i7-10750H CPU，16 GB 内存，采用 NVIDIA Geforce RTX 3090 GPU 进行加速；使用 Pytorch 框架对算法进行实现，网络损失函数权重 α 、 β 、 λ 分别设置为 0.7、0.2、0.1。对未来 {10, 20, 30} 个时刻的电力数据进行预测；epoch 设置为 20，Dropout 设置为 0.1，学习率为 0.000 1，加噪步数 steps 取 1000，潜在变量维度取 10，采用“早停法”进行训练防止模型过拟合。

2.4 实验结果分析

为验证 DHVAE 在多步预测上的有效性，采用 DeepAR 算法与 LSTNet^[16] 算法进行对比，以测试集数据作为测试验证，实验结果如表 1 所示。

表 1 电力负荷预测结果对比表

评价指标	预测步长	预测模型		
		DHVAE	DeepAR	LSTNet
MSE	10	0.145 6	0.197 7	0.173 4
	20	0.201 2	0.246 4	0.273 4
	30	0.246 4	0.273 2	0.251 2
MAE	10	0.253 5	0.294 4	0.336 5
	20	0.301 6	0.345 6	0.337 4
	30	0.364 6	0.396 6	0.373 5

观察预测结果对比表可以发现，DHVAE 相比 DeepAR、LSTNet 模型，在预测步长为 10 时，MSE 指标提升了 35.78%、19.09%，MAE 指标分别提升了 16.13%、32.74%；预测步长为 20 时，MSE 指标提升了 22.46%、35.88%，MAE 指标分别提升了 14.58%、11.87%；预测步长为 30 时，MSE 指标提升了 10.88%、1.94%，MAE 指标分别提升了 8.77%、2.44%。由此可以得出结论：在多个步长下的预测实验中，DHVAE 均能表现出最佳的预测效果，这证明了 DHVAE 在多步预测领域上是显著有效的。

为了直观观察各模型在不同预测步长上的预测指标，对预测结果进行随机采样，并绘制出 3 个预测步长上的预测结果，如图 4 所示。




图 4 多步预测负荷曲线对比图

通过观察图 4 曲线，文章所提出的 DHVAE 算法与 DeepAR 算法以及 LSTNet 算法的电力负荷预测曲线与预测真

值曲线在趋势上是基本一致的,只在负荷波动处存在一定的偏差,可以作为对未来负荷曲线预测的理论支撑。

图5是各模型在不同预测步长上的MAPE指标柱状图,在预测步长为10与20时,DHVAE模型在MAPE指标均能表现最佳性能;对于更长的预测步长30,DHVA性能指标仅次于LSTNet模型,MAPE指标仍低于3%,表现出良好的预测性能。




图5 模型不同预测步长上MAPE对比图

3 结语

本研究提出了一种基于DDPM与HVAE的电力负荷预测模型DHVAE,模型中的前向扩散过程有效地将复杂的非线性数据转化为易于处理的形式;接着HVAE模块通过隐变量分布生成更接近真实的数据;最后DSM模块进一步提升了预测结果的可靠性,减少了模型偏差。实验结果表明,DHVAE模型在多个预测指标上的表现均优于其他模型,为多步电力负荷预测领域提供了一种新方法。在后续的研究中,将继续推进多因素影响下的多步电力负荷预测研究,在保证预测准确度的情况下,进一步提升预测长度,为电力系统优化调度提供更可靠的理论支撑。

参考文献:

- [1] 朱继忠,董瀚江.数据驱动的综合能源系统负荷预测综述[J].中国电机工程学报,2021,41(23):7905-7923.
- [2] 陈启鑫,吕睿可,郭鸿业,等.面向需求响应的电力用户行为建模:研究现状与应用[J].电力自动化设备,2023,43(10):23-37.
- [3] 谭风雷,张军.基于趋势变化分段的电力负荷组合预测方法[J].华北电力大学学报(自然科学版),2020,47(2):17-24.
- [4] 李颖玥,王勋.基于指数加权移动平均多维组合模型的电力负荷预测[J].华东交通大学学报,2019,36(5):102-108.
- [5] 霍娟,孙晓伟.电力负荷预测算法比较-随机森林与支持向量机[J].电力系统及其自动化学报,2019,31(7):129-

134.

- [6] 龙干,黄媚.基于改进多元宇宙算法优化ELM的短期电力负荷预测[J].电力系统保护与控制,2022,50(19):99-106.
- [7] 张月,胡春光,赵罡.基于并行时序卷积神经网络的电力负荷短期预测[J].电力需求侧管理,2023,25(6):43-49.
- [8] 王子乐,王子谋,蔡莹,等.基于长短期记忆神经网络组合算法的短期电力负荷预测[J].现代电力,2023,40(2):201-209.
- [9] 史含笑,王雷春.结合LSTM和自注意力机制的图卷积神经网络短期电力负荷预测[J].计算机应用,2024,44(1):311-317.
- [10] 杨雷,罗雪红,韩鹏等.基于人工智能算法的电力系统负荷预测研究综述[J].电工技术,2024(12):57-60.
- [11] NICHOL A Q, DHARIWAL P. Improved denoising diffusion probabilistic models[C]//International Conference on Machine Learning, PMLR. New York: JMLR.org, 2021:8162-8171.
- [12] VAHDAT A, KAUTZ J. NVAE: A deep hierarchical variational autoencoder[C]//Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2020: 19667-19679.
- [13] SALINAS D, FLUNKERT V, GASTHAUS J, et al. DeepAR: Probabilistic forecasting with autoregressive recurrent networks[J]. International journal of forecasting, 2020, 36(3): 1181-1191.
- [14] LI Y, LU X, WANG Y, et al. Generative time series forecasting with diffusion, denoise, and disentanglement[C]//Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2022, 35: 23009-23022.
- [15] LI Z Y, CHEN Y B, SOMMER F T. Learning energy-based models in high-dimensional spaces with multi-scale denoising score matching[DB/OL]. (2019-12-20)[2024-05-23]. <https://doi.org/10.48550/arXiv.1910.07762>.
- [16] LAI G, CHANG W C. Modeling long-and short-term temporal patterns with deep neural networks[C]//The 41st international ACM SIGIR conference on research .& development in information retrieval. New York: ACM, 2018: 95-104.

【作者简介】

陈萌(1999—),男,湖北黄冈人,硕士研究生,研究方向:电力大数据分析等。

(收稿日期:2024-08-14)