

## 基于条件生成对抗网络的短期负荷预测

林 珊, 王 红, 齐林海, 冯函宇, 苏 盈  
(华北电力大学控制与计算机工程学院, 北京市 102206)

**摘要:** 精准的短期负荷预测对电力系统制定合理生产计划、提高经济效益、保证电网安全运行具有重要意义。为学习非线性负荷数据中隐含的深层关系,提高短期负荷预测精度,文中提出一种基于条件生成对抗网络的短期负荷预测模型。所提模型使用卷积神经网络构建生成模型和判别模型,以负荷影响因素作为条件,并引入特征损失函数作为判别模型部分隐藏层的损失函数。然后,通过条件生成对抗网络的博弈训练,使生成模型以负荷影响因素为条件生成预测负荷数据,从而进行短期负荷预测。最后,以美国某地区3年的负荷作为实际算例,对比所提模型与其他模型的预测结果,验证了所提模型在兼顾泛化能力的同时可以提高短期负荷的预测精度。

**关键词:** 条件生成对抗网络; 负荷数据; 短期负荷预测; 卷积神经网络

### 0 引言

在现代电力系统中,电力需求预测占有重要地位,对不同时间范围内未来负载的精准预测可以提高电力系统的管理效率。短期负荷预测是指对未来几分钟到一个星期的负荷进行预测。精准的短期负荷预测对电力系统制定合理的生产计划,避免造成资源浪费,保证电网安全可靠运行,提高经济效益有着重要作用。随着非线性负荷数据越来越复杂,更精准的负荷预测可以提高发电设备的利用率和经济调度的有效性。

20世纪70年代,负荷预测通常采用统计学方法来进行建模和预测。主要包括线性回归(LR)模型<sup>[1]</sup>、支持向量回归(SVR)模型<sup>[2]</sup>、自回归积分滑动平均(ARIMA)模型<sup>[3-4]</sup>。这些模型主要针对线性关系来构建,忽略了气候、日期类型等因素对短期负荷预测的影响,预测准确率较低。随着人工智能的出现,机器学习以及深度学习方法被广泛应用到短期负荷预测中。文献[5-8]使用支持向量机(SVM)模型,在样本有限的情况下,SVM模型可以得到系统最优解,且能达到较为理想的预测精度,但数据量增大时其应用效果不如神经网络模型。文献[9]将递归神经网络(RNN)与蚁群优化算法结合,该模型兼具蚁群优化的优点与RNN的时序特性,但是RNN在处理较长时间序列时易出现梯度消失问题。文献[10-12]采用基于误差反向传播(BP)模型,该模型结

构简单、适用性强,被广泛应用于短期负荷预测中,但BP模型易陷入局部最小值,不能获得全局最优解。文献[13-14]提出基于长短期记忆(LSTM)网络模型,该模型能够兼顾数据时序性与非线性关系,具有较高的预测精度,但对于复杂度较高的数据样本,难以挖掘其深层关系。

生成对抗网络(generative adversarial network, GAN)<sup>[15]</sup>能够捕捉复杂的非线性序列数据间隐含的深层关系,可有效提高预测精度,在多个应用领域均有显著的优越性。文献[16]提出了一种新型的用于金融时间序列预测的GAN模型,并验证了模型对金融时间序列预测的准确性。文献[17]提出了一种基于GAN的双重语义感知缺失重构方法,解决了量测数据修复问题,提高了电力数据利用价值。文献[18]采用了基于全局GAN和局部GAN相融合的方法进行变电站工作人员行为预测,通过提取时序动态实现了较高的预测精度。文献[19]使用GAN构建了在数据匮乏场景下的空间负荷预测模型,并通过实例验证了预测方法的有效性。

考虑到短期负荷预测受历史负荷数据、气候和日期等因素影响,本文引入条件GAN(conditional GAN, CGAN)<sup>[20]</sup>进行短期负荷预测。一般回归模型主要针对线性关系进行构建,忽略了气候、日期类型等因素对短期负荷预测的影响。本文提出将数据生成方法应用于短期负荷预测,把历史负荷数据、气候、日期类型等负荷影响因素作为条件与噪声输入生成模型,把预测数据与真实数据分别输入判别模型,通过CGAN的博弈训练,使生成模型以负荷影响因素为条件生成预测负荷数据,并在判别模型的

收稿日期: 2020-08-04; 修回日期: 2020-12-28。

上网日期: 2021-03-18。

部分隐藏层引入特征损失函数<sup>[21]</sup>,进一步提高预测精度。在实际负荷预测应用中,将噪声以及负荷影响因素输入训练好的模型,即可进行预测。本文通过实验与其他算法进行对比,验证了所提出的基于CGAN的负荷预测模型在兼顾泛化能力的同时,提高了短期负荷预测的精度。

## 1 CGAN

GAN包括2个部分:生成模型和判别模型。生成模型的作用是学习真实样本的分布,并产生新的样本,尽可能“欺骗”判别模型。判别模型的作用是尽可能判断输入的样本是否来自生成模型。当模型充分学习到数据隐含深层关系并达到平衡后,理论上模型所生成的数据可以无限逼近于真实数据<sup>[22]</sup>。CGAN是在GAN的基础上对其进行的改进。CGAN的结构如图1所示。

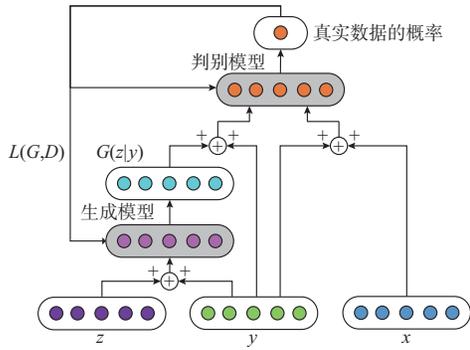


图1 CGAN结构  
Fig.1 CGAN structure

CGAN中除了生成模型和判别模型外,还额外增加了条件 $y$ 作为输入。随机噪声 $z$ 与条件值 $y$ 输入生成模型, $G(z|y)$ 为生成模型所生成的样本。真实样本 $x$ 与生成样本 $G(z|y)$ 分别和条件 $y$ 一起输入判别模型进行判别,判别模型的判别结果要反馈给生成模型和判别模型。生成模型和判别模型根据反馈结果更新自身参数进行优化,提高各自的生成能力和判别能力。网络参数及其意义见表1。

表1 网络参数及其意义  
Table 1 Network parameters and their significance

参数	参数意义	实际意义
$x$	真实样本	实测负荷数据
$y$	条件值	历史负荷数据和其他影响因素
$z$	噪声值	随机噪声数据
$G(z y)$	生成样本	预测负荷数据
$L(G,D)$	反馈	网络模型的损失函数

在短期负荷预测中,使用历史负荷数据和其他影响因素构建数据集。其中,使用实测负荷数据作为真实样本,以负荷影响因素作为条件。将随机噪声与负荷影响因素输入生成模型生成预测负荷数据,预测负荷数据与实测负荷数据分别与负荷影响因素一起输入判别模型。随机噪声为符合高斯分布的随机变量,CGAN的生成模型在以负荷影响因素为条件的情况下生成预测负荷数据,从而进行短期负荷预测。

生成模型的任务是生成尽量接近实测负荷数据分布的预测负荷数据,噪声 $z$ 与负荷影响因素 $y$ 拼接后输入生成模型,通过生成模型输出预测负荷数据 $G(z|y)$ 。判别模型不仅需要判断预测负荷数据 $G(z|y)$ 与实测负荷数据 $x$ 的相似度,还需判断预测负荷数据 $G(z|y)$ 是否满足负荷影响因素 $y$ 。模型中的生成模型与判别模型的损失函数 $L_G$ 和 $L_D$ 分别为:

$$L_G = -E_{z,y}(D(G(z|y)|y)) \quad (1)$$

$$L_D = -E_{x,y}(D(x|y)) + E_{z,y}(D(G(z|y)|y)) \quad (2)$$

其中, $E_{z,y}(\cdot)$ 表示对 $z,y$ 分布的期望值; $G(\cdot)$ 和 $D(\cdot)$ 分别为生成模型和判别模型输出的数据。生成模型希望提高预测负荷数据 $G(z|y)$ 判别模型的输出值,而判别模型希望降低预测负荷数据 $G(z|y)$ 的输出值并调高实测负荷数据 $x$ 的输出值。因此CGAN模型的损失函数 $L_{CGAN}$ 是含有条件概率的二元极大极小值博弈,可定义为:

$$\min_G \max_D L_{CGAN} = E_{x,y}(\ln D(x|y)) + E_{z,y}(\ln(1 - D(G(z|y)|y))) \quad (3)$$

CGAN的损失函数结合传统的损失函数(例如L1和L2范数)使生成模型的生成结果更加接近真实数据分布。L2范数通常用于图像翻译<sup>[23]</sup>,与L2范数相比,CGAN使用L1范数作为损失函数得到的生成结果更加准确。重新定义的L1范数损失函数 $L_{L1}$ 为:

$$L_{L1} = E_{x,y,z}(\|x - G(z|y)\|) \quad (4)$$

式中: $\|\cdot\|$ 表示计算绝对偏差。

本文利用判别模型的隐藏层量度生成模型生成的预测数据与真实数据之间的特征值偏差,进一步提高GAN预测短期负荷的准确率。整个GAN不断进行迭代优化,使得生成模型的预测结果更加准确。特征损失函数 $L_{per}$ 为:

$$L_{per}(G, x) = E_{x,y,z}(\lambda_i P_i(G, x)) \quad (5)$$

$$P_i(G, x) = \frac{1}{C_i H_i W_i} \|h_i(x) - h_i(G)\| \quad (6)$$

式中： $P_i(G, x)$ 为生成模型生成的预测数据和真实负荷数据在隐藏层 $h_i$ 的平均偏差值，其中 $h_i$ 为判别模型的第 $i$ 层隐藏层； $h_i(x)$ 为在隐藏层 $h_i$ 的真实负荷数据值； $h_i(G)$ 为在隐藏层 $h_i$ 由生成模型生成的预测数据值； $C_i$ 、 $H_i$ 和 $W_i$ 分别为隐藏层 $h_i$ 的通道数、高度和宽度值； $\lambda_i$ 为权重参数。

将损失函数式(3)一式(5)结合后，网络模型的总损失函数为：

$$L(G, D) = \min_G \max_D L_{CGAN} + \lambda_{L1} L_{L1} + \lambda_{per} L_{per}(G, x) \quad (7)$$

式中： $\lambda_{L1}$ 和 $\lambda_{per}$ 为损失函数的权重参数。

## 2 基于CGAN的短期负荷预测模型

基于CGAN的短期负荷预测模型见图2，主要包括数据集构建、网络模型训练和负荷预测结果对比。

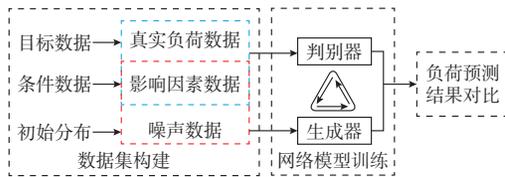


图2 基于CGAN的短期负荷预测模型  
Fig. 2 Short-term load forecasting model based on CGAN

构建数据集主要指构建训练及测试数据集并进行数据预处理，从而确定网络模型的输入、输出变量。初始分布为噪声数据，是由函数产生的均值为0、方差为1并符合高斯分布的随机变量。负荷影响因素为条件数据，包括历史负荷数据、气候数据、日期类型数据等。真实负荷数据为模型的目标数据。在训练短期负荷预测网络模型的过程中，本文采用CGAN结合特征损失函数用于短期负荷预测。随机噪声数据与条件数据输入生成模型，生成模型输出预测负荷数据；预测负荷数据、真实负荷数据分别与条件数据输入判别模型，判别模型输出的输入数据为真实数据的概率。生成模型与判别模型通过不断进行对抗训练优化自身权重，使整个基于CGAN的负荷预测模型达到最优。

最后，使用训练好的预测模型进行负荷预测，并与其他预测模型的预测结果进行对比。使用本文所构建的负荷预测模型时，将各组测试数据集的内容依次输入生成模型，输出每日的预测结果，并分别与每日的真实值进行对比，得到模型的预测精度。进

行对比实验时，将相同的测试数据输入基于其他方法的短期负荷预测模型中，使用平均绝对误差 $y_{MAE}$ 、均方根误差 $y_{RMSE}$ 和预测精度 $y_{FA}$ 作为预测准确度的评价指标，对比不同预测模型的预测结果。

### 2.1 数据分析与处理

#### 2.1.1 主要影响因素的历史负荷数据

本文所采用的数据集中负荷数据的采样频率为1次/h，每日采集24个负荷数据点。短期负荷预测选择预测未来24h的负荷。

为提高生成模型的预测准确率以及处理数据的效率，需选择合理的历史负荷数据进行输入。由于负荷数据具有随机性，本文通过计算样本数据的自相关性系数来确定输入变量的时间序列，即历史负荷数据的长度。自相关系数不仅能反映各滞时状态间的相关关系，还可反映序列的周期规律<sup>[24]</sup>。滞后时间为 $m$ 的时间序列的自相关系数 $A$ 的计算公式为：

$$A = \frac{\sum_{k=1}^{l-m} (x_k - \bar{x})(x_{k+m} - \bar{x})}{\sum_{k=1}^l (x_k - \bar{x})^2} \quad (8)$$

式中： $x_k$ 为输入时间序列 $k$ 的值； $\bar{x}$ 为 $x_k$ 的平均值； $l$ 为时间序列的长度。

根据式(8)计算已有历史负荷数据集的自相关系数，如附录A图A1所示。历史负荷数据应当充分包含数据的整体特征，但如果选择过长时间的历史负荷数据会造成维数灾，增加训练难度。从图A1可看出，当滞后时间为168h时，自相关系数非常接近0，168h之后自相关系数变化缓慢且无限接近0，代表着比预测负荷数据的前168h更早的历史负荷数据与未来24h的负荷数据相关性非常小。因此，选择预测负荷数据的前168h历史负荷数据作为主要影响因素。

#### 2.1.2 除负荷外的其他影响因素

根据分析研究已有数据集的负荷特性，确定除负荷外的其他影响因素包括：预测日各时刻温度、湿度、风速、气压值、预测日前一天的最高最低温度、预测日为星期几以及该日是否为节假日。本文使用1~7代表星期一至星期日，如果为节假日则节假日位设置为1，否则设置为0。例如，预测日为星期日则在星期位设置为7，在节假日位设置为1；若预测日为国庆节且恰逢星期二，则在星期位设置为2，在节假日位设置为1。温度、湿度等影响因素需要使用评价指标进行量度。

### 2.1.3 数据预处理

考虑到实验数据分布区间跨度较大,会影响深度学习模型在进行梯度下降求解时的下降速度,不利于模型收敛,因此对实验数据采用 min-max 归一化操作使其映射至  $[0, 1]$  区间内,归一化公式为:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

式中:  $X_{\text{norm}}$  为归一化后的数据;  $X$  为当前数据;  $X_{\min}$  为数据中最小值;  $X_{\max}$  为数据中最大值。

## 2.2 模型的网络结构

在实际训练中,当 GAN 面对的数据特征量较多时,不仅网络很难稳定训练,而且还会有收敛速度慢、模式崩溃、生成样本质量有待提高等问题。为解决以上问题,本文引入卷积神经网络(CNN)<sup>[25]</sup>来构造生成模型与判别模型的内部结构<sup>[18]</sup>,CNN 不仅具有多隐藏层特征提取的强大能力,而且能够共享卷积核,对高维数据处理无压力,引入 CNN 可提高 CGAN 的稳定性、收敛速度和生成模型生成数据的质量。一维卷积模型可训练的样本数量有限,在参数输入过多时,样本容易过拟合<sup>[26]</sup>,且一维卷积模型的抗噪性能不如二维卷积模型<sup>[27]</sup>。由一维卷积网络搭建的 CGAN 模型的预测结果与由二维卷积网络搭建的 CGAN 模型的预测结果的对比见附录 A 表 A1。为增强模型整体的泛化能力和鲁棒性,采用二维卷积模型的结构去构建预测模型,因此,需要将一维序列数据进行二维等同信息度变换,排成  $n \times n$  的二维形式进行卷积更有利于模型提取特征。为进一步提高预测的准确率,采用部分判别器隐藏层计算特征偏差的方法来优化网络结构。

为保证二维卷积核滑动采样的完整性,输入数据与输出数据均构成  $n \times n$  矩阵。将随机噪声以及条件数据拼接为一个  $n \times n$  矩阵后输入 CNN。为了让网络能自主学习更适合的空间采样方法,不使用 CNN 中的空间池化,采用步长卷积(strided convolutions)<sup>[28]</sup>使网络能够在自主学习空间下采样。在层级之间采用批标准化(batch normalization)操作来加速收敛并减缓过拟合,使梯度传播层次更深。并在输出层采用 tanh 激活函数,其余层采用 ReLU 激活<sup>[29]</sup>,网络最终生成预测数据。

考虑短期负荷预测的特性,生成模型由 3 层的 CNN 构成,结构如图 3 所示。输入层经 32 个  $5 \times 5$  的卷积核进行卷积后得到卷积层  $C_1$ ,经 64 个  $5 \times 5$  的卷积核进行卷积后得到卷积层  $C_2$ ,经 1 个  $5 \times 5$  的

卷积核进行卷积后得到输出,滑动步长均为 2。

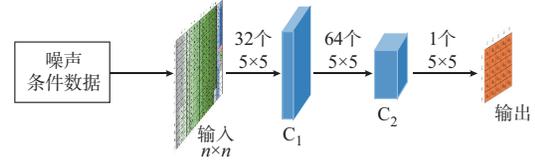


图 3 生成器网络结构

Fig. 3 Network structure of generator

条件数据分别与生成样本、真实样本作为输入数据输入判别模型,判别模型同样将输入数据拼接为一个矩阵,矩阵将作为卷积层的输入。判别模型由 3 层的 CNN 构成,判别模型的隐藏层使用 LeakyReLU 函数作为激活函数,在实验过程中,判别模型的第 2 和第 3 层隐藏层应用特征损失函数。最后,使用全连接和 sigmoid 激活函数进行真假判断,使结果映射到  $(0, 1)$  之间。

判别模型中卷积层  $C_1$  由 32 个  $5 \times 5$  的卷积核进行卷积后得出,卷积层  $C_2$  由 64 个  $5 \times 5$  的卷积核进行卷积得到,卷积层  $C_3$  由 128 个  $5 \times 5$  的卷积核进行卷积得到,滑动步长均为 2。最后,全连接输出判别结果,其结构如图 4 所示。

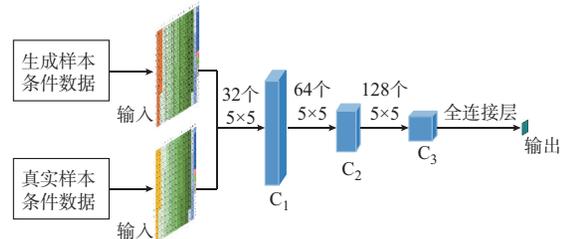


图 4 判别器网络结构

Fig. 4 Network structure of discriminator

### 2.3 模型的网络训练

在训练 CGAN 时一般采用生成模型与判别模型交替训练的方式。训练生成模型的过程中,生成模型的权重值需要根据生成模型生成的预测数据与真实数据的偏差、判别模型的判别结果以及特征向量偏差 3 个方面的约束来设定。训练判别模型的过程中,需要将条件数据、生成模型生成的预测数据输入判别模型,判别模型需要判别输入数据为待预测的真实负荷数据的概率,并根据鉴别偏差来更新自身的参数。训练过程中应用 Adam 优化器和随机梯度下降算法,判别模型更新一次后再更新生成模型,训练过程中的参数设置见附录 A 表 A2。

### 2.4 评价指标

为评估各种模型的预测性能,本文提出使用平

均绝对误差  $y_{MAE}$ 、均方根误差  $y_{RMSE}$  以及预测精度  $y_{FA}$  作为评价标准,各公式定义如下。

$$y_{MAE} = \frac{1}{N} \sum_{j=1}^N |x_{\text{real}}(j) - x_{\text{pred}}(j)| \quad (10)$$

$$y_{RMSE} = \sqrt{\frac{\sum_{j=1}^N (x_{\text{real}}(j) - x_{\text{pred}}(j))^2}{N}} \quad (11)$$

$$y_{FA} = \frac{1}{N} \sum_{j=1}^N \left( 1 - \frac{|x_{\text{real}}(j) - x_{\text{pred}}(j)|}{x_{\text{real}}(j)} \right) \times 100\% \quad (12)$$

式中:  $x_{\text{real}}(j)$  为第  $j$  个真实负荷值;  $x_{\text{pred}}(j)$  为第  $j$  个预测负荷值;  $N$  为预测个数。当  $y_{MAE}$  与  $y_{RMSE}$  值越小,  $y_{FA}$  值越大时, 代表预测负荷值与真实负荷值越接近, 即预测的准确率越高。

### 3 实验结果及对比

#### 3.1 实验数据准备

本文实验使用来自美国东部某地区 2016—2018 年 3 年的电力负荷数据以及气象、日期类型数据作为数据集。实验取 2016 年和 2017 年数据作为训练集进行训练, 2018 年数据作为测试集。负荷数据集为美国某地的电力负荷数据, 主要为功率数据, 负荷预测数据为发电厂制定合理的生产计划提供支撑, 避免资源浪费。负荷数据采集频率为 1 次/h, 气象要素数据(温度、湿度、风速、气压)的采集频率为 1 次/h。为了说明不同的条件数据对短期负荷预测模型的影响, 进行如下对比实验。已知预测的未来 24 h 负荷数据与之前 168 h 负荷数据相关,  $D_{24}$  代表前 168 h 历史负荷数据, 用来预测时段内间隔 1 h 的气象要素(即每个要素选取全部 24 个采样点)、预测日前一日的最高和最低温度和预测日为星期几及其是否为节假日。 $D_{12}$ 、 $D_6$ 、 $D_4$  分别为间隔 2 h、4 h、6 h 的历史负荷数据,  $D_0$  表示完全不考虑气候影响的历史负荷数据,  $L_{A0}$  表示仅通过负荷数据预测。

通过对比实验计算测试集的预测误差以及精度, 结果如表 2 所示, 表中  $\bar{y}_{MAE}$ 、 $\bar{y}_{RMSE}$  与  $\bar{y}_{FA}$  为对应评价指标的平均值。当仅有历史负荷数据作为条件数据进行输入时, 模型能学习到的有效信息比较少, 预测准确率最低。当加入气象及日期等影响因素数据后, 预测的准确率有所提高, 当取预测时段内每隔 4 h 的温度、湿度、风速、气压数据时, 预测效果达到最佳,  $\bar{y}_{MAE}$  达到了 209.46 MW,  $\bar{y}_{RMSE}$  大幅降低达到 234.03 MW, 预测精度  $\bar{y}_{FA}$  为 97.82%。因此, 选择预测日间隔 4 h 的气象要素作为部分影响因素。

表 2 不同条件数据预测误差和精度对比  
Table 2 Comparison of forecasting error and accuracy for different conditional data

条件数据	$\bar{y}_{MAE}/\text{MW}$	$\bar{y}_{RMSE}/\text{MW}$	$\bar{y}_{FA}/\%$
$D_{24}$	298.37	311.41	97.41
$D_{12}$	251.75	274.28	97.55
$D_6$	209.46	234.03	97.82
$D_4$	243.68	259.22	97.57
$D_0$	351.73	375.53	96.26
$L_{A0}$	421.93	446.27	93.68

输入模型的条件数据包括前 168 h 历史负荷数据(前 7 d 的历史负荷数据), 预测时段内的温度(6 个)、湿度(6 个)、风速(6 个)、气压(6 个), 预测日前一日的最高和最低温度, 预测日为星期几及是否为节假日, 共计 196 个条件数据。

生成模型的输出为预测负荷, 将输出未来 24 h 的预测数据扩充为 25 h, 构成  $5 \times 5$  矩阵, 如附录 A 图 A2 所示。扩充的 1 h 预测数据仅用于边缘扩充并不参与预测后的指标运算。生成模型的输入为条件数据与噪声数据。条件数据为历史负荷数据、气候数据、日期类型数据, 共 196 个数据。为保持噪声数据与生成模型输出数据的对应关系, 由函数产生 25 个随机噪声数据作为输入。生成模型将上述输入数据按照噪声数据、历史负荷数据、气候数据、日期类型数据的排列方式进行拼接, 对每条样本进行边缘数据扩充, 在最后填充 4 个 0 使其构成  $15 \times 15$  输入矩阵见图 A3。为提高预测的准确率, 生成样本与真实样本数量保持一致, 所以取预测的 25 h 真实负荷数据作为真实样本, 将条件数据分别与生成的预测负荷数据、真实的负荷数据输入判别模型。与生成模型相同, 判别模型的输入数据拼接后同样将 0 填充 4 次, 每条样本构成  $15 \times 15$  矩阵, 如图 A4 和图 A5 所示。事实上, 边缘数据的扩充对样本特征的提取不会产生影响。样本数据扩充也可以最后一个数据值或均值来进行扩充。本文通过对比上述 3 种数据扩充方法, 采用  $\bar{y}_{MAE}$ 、 $\bar{y}_{RMSE}$  与  $\bar{y}_{FA}$  作为评价指标, 结果如表 A3 所示, 从表中可以看出, 3 种方式填充对最终结果没有明显影响。

由函数产生的随机变量作为噪声, 前 7 d 历史负荷数据、其他影响因素和预测当日的负荷数据构成一条训练样本(即每个训练样本中共包含 8 d 的负荷数据, 前 7 d 的负荷数据为条件, 最后 1 d 的负荷数据为真实样本)。训练集为 2016 年、2017 年(共 731 d)数据, 采用滑动时间窗的方式, 以 8 d 为滑动时间窗口, 以 1 d 为步长, 共构成 724 个训练样本。测试样本与训练样本构成一致。测试集为 2018 年(共 365 d)数据, 可构成 358 个测试样本。

### 3.2 模型训练和验证

随着训练的进行,通过生成模型与判别模型不断进行博弈对抗,判别模型不断“被迫”增强其判别真实负荷数据的能力,而生成模型“被迫”生成越来越接近真实负荷数据的预测数据来欺骗判别模型,最终达到Nash均衡。

验证模型使用2018年负荷数据,测试样本取自未经过训练的测试集,从而对模型的泛化能力进行验证。取2018年11月26日(星期一)至12月2日(星期日)的负荷预测值以及实测值作为验证样本,将噪声和条件数据输入生成模型,生成预测的负荷数据,如附录A图A6所示。预测下一日负荷时,本模型预测出的负荷数据并不参与,仍使用其前7d的实际负荷进行预测。从图A6中可以看出,基于CGAN的预测模型的预测结果与实际值基本一致。

分别计算2018年11月26日至12月2日的 $\bar{y}_{MAE}$ 、 $\bar{y}_{RMSE}$ 与 $\bar{y}_{FA}$ 值,如表3所示。由表可知, $\bar{y}_{MAE}$ 为214.70 MW, $\bar{y}_{RMSE}$ 为228.69 MW, $\bar{y}_{FA}$ 为97.79%,模型可以很好地预测未来24 h负荷数据。

### 3.3 实验结果及对比

采用基于CGAN的预测模型对2018年的数据进行测试,并与经参数调优后的BP、LSTM网络、SVR、LR、ARIMA模型进行对比。各模型均使用相同负荷数据以及气象、日期类型数据进行预测,各模型的参数设置如附录A表A4所示。

图5为2018年11月26日至12月2日连续7d的实测负荷数据和不同预测模型的预测结果对比。从图中可以看出,6种方法都能对负荷变化趋势做出很好的预测,本文所提模型的预测结果与实际负荷曲线的重合度最高,结果最为理想。

表3 单日预测误差及精度  
Table 3 Forecasting error and accuracy for a single day

日期	$\bar{y}_{MAE}/\text{MW}$	$\bar{y}_{RMSE}/\text{MW}$	$\bar{y}_{FA}/\%$
2018年11月26日	212.63	228.31	97.79
2018年11月27日	222.83	241.91	97.67
2018年11月28日	217.84	221.36	97.86
2018年11月29日	214.41	229.42	97.75
2018年11月30日	203.12	219.56	97.89
2018年12月1日	211.56	221.64	97.87
2018年12月2日	220.53	238.62	97.67
平均值	214.70	228.69	97.79

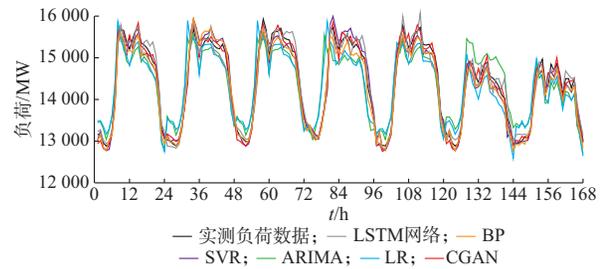


图5 不同预测模型的预测结果对比  
Fig. 5 Comparison of forecasting results for different forecasting models

不同季节预测误差及精度对比如表4所示,由表中数据可以看出,4个季节中,本文所提模型的平均值评价指标与其他5种模型的评价指标相比是最小的,4个季节的误差平均值 $\bar{y}_{MAE}$ 为218.26 MW, $\bar{y}_{RMSE}$ 为234.03 MW,平均预测精度 $\bar{y}_{FA}$ 为97.82%,准确率高出其他5种模型的准确率。本文方法在误差以及精度指标上都有明显提升。

表4 不同季节预测误差及精度对比  
Table 4 Comparison of forecasting error and accuracy in different seasons

模型	春季			夏季			秋季			冬季			四季平均值		
	$\bar{y}_{MAE}/\text{MW}$	$\bar{y}_{RMSE}/\text{MW}$	$\bar{y}_{FA}/\%$												
CGAN	224.36	241.27	97.73	214.52	231.57	97.80	202.58	214.8	97.96	231.56	248.47	97.77	218.26	234.03	97.82
BP	468.52	485.93	95.78	437.38	453.26	96.03	462.75	479.37	95.80	453.82	471.05	95.98	455.61	472.40	95.90
LSTM网络	316.26	339.34	97.06	328.63	345.16	96.82	331.47	349.98	96.78	342.73	358.04	96.73	329.77	348.13	96.85
SVR	401.34	417.17	96.57	421.85	436.83	96.49	431.71	446.27	96.27	413.74	429.87	96.42	417.16	432.54	96.44
LR	628.12	644.14	93.75	637.45	653.23	93.65	624.36	638.54	93.79	618.51	635.11	93.87	627.11	642.76	93.76
ARIMA	563.81	578.14	94.27	548.37	565.91	94.30	541.52	558.37	94.32	548.36	559.21	94.34	550.52	565.41	94.31

为检验本文所提模型在节假日等特殊条件下的预测效果,分别选取了感恩节(2018年11月22日)、圣诞节假期(2018年12月24日和12月25日)单日的预测结果与基于BP、LSTM网络、SVR、LR、

ARIMA模型的预测结果进行对比,如表5所示。在节假日,基于CGAN的模型的预测精度最高,相较于其他模型误差明显降低,预测效果非常理想。

表5 节假日不同模型预测误差及精度对比  
Table 5 Comparison of forecasting error and accuracy for different models in holidays

模型	2018年11月22日			2018年12月24日			2018年12月25日		
	$y_{MAE}/MW$	$y_{RMSE}/MW$	$y_{FA}/\%$	$y_{MAE}/MW$	$y_{RMSE}/MW$	$y_{FA}/\%$	$y_{MAE}/MW$	$y_{RMSE}/MW$	$y_{FA}/\%$
CGAN	208.63	225.51	97.73	189.63	205.89	98.06	224.56	241.52	97.62
BP	489.27	502.92	95.70	447.29	461.53	95.87	452.36	471.38	96.11
LSTM网络	351.91	368.37	96.83	320.80	336.84	96.84	337.17	354.54	96.64
SVR	385.71	402.31	96.67	416.58	433.25	96.37	405.58	421.07	96.48
LR	615.36	637.03	93.98	643.25	656.17	93.57	617.45	632.93	93.87
ARIMA	505.72	518.94	94.69	570.32	586.91	94.10	542.64	558.68	94.39

## 4 结语

目前的短期负荷预测模型无法处理复杂非线性负荷数据间隐含的深层关系,从而导致模型的预测准确率有所欠缺。本文提出一种基于CGAN的模型进行短期负荷预测。通过对抗可以学习到复杂的非线性序列数据间隐含的深层关系,并生成新的数据。模型以负荷影响因素作为条件,使生成模型生成预测负荷数据,并在判别模型中结合特征损失函数来计算预测数据与真实数据之间的特征值偏差以提高准确率,从而实现了短期负荷预测。本文通过实验与其他预测模型对比证明了本文提出的模型在预测精度上具有突出优势,并验证了在节假日等特殊日期基于CGAN的负荷预测模型依然具有很高的准确率。本文使用的数据集仅包含单一类型的负荷数据,后续工作将分析不同类型负荷数据的特性以及考虑实时电价等因素对负荷预测的影响,进一步提高模型的预测准确率以及普适性。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

## 参考文献

- [1] 耿光飞,郭喜庆.模糊线性回归法在负荷预测中的应用[J].电网技术,2002,26(4):19-21.  
GENG Guangfei, GUO Xiqing. Application of fuzzy linear regression to load forecasting [J]. Power System Technology, 2002, 26(4): 19-21.
- [2] 蒋敏,顾东健,孔军,等.基于在线序列极限支持向量回归的短期负荷预测模型[J].电网技术,2018,42(7):2240-2247.  
JIANG Min, GU Dongjian, KONG Jun, et al. Short-term load forecasting model based on online sequential extreme support vector regression [J]. Power System Technology, 2018, 42(7): 2240-2247.
- [3] OSTERTAGOVÁ E, OSTERTAG O. Forecasting using simple exponential smoothing method [J]. Acta Electrotechnica et Informatica, 2012, 12(3): 62-66.
- [4] 艾欣,周志宇,魏妍萍,等.基于自回归积分滑动平均模型的可转移负荷竞价策略[J].电力系统自动化,2017,41(20):26-31.  
AI Xin, ZHOU Zhiyu, WEI Yanping, et al. Bidding strategy for time-shiftable loads based on autoregressive integrated moving average model [J]. Automation of Electric Power Systems, 2017, 41(20): 26-31.
- [5] 赵登福,庞文晨,张讲社,等.基于贝叶斯理论和在线学习支持向量机的短期负荷预测[J].中国电机工程学报,2005,25(13):8-13.  
ZHAO Dengfu, PANG Wenchen, ZHANG Jianshe, et al. Based on Bayesian theory and online learning SVM for short term load forecasting [J]. Proceedings of the CSEE, 2005, 25(13): 8-13.
- [6] 吴倩红,高军,侯广松,等.实现影响因素多源异构融合的短期负荷预测支持向量机算法[J].电力系统自动化,2016,40(15):67-72.  
WU Qianhong, GAO Jun, HOU Guangsong, et al. Short-term load forecasting support vector machine algorithm based on multi-source heterogeneous fusion of load factors [J]. Automation of Electric Power Systems, 2016, 40(15): 67-72.
- [7] 曾鸣,吕春泉,田廓,等.基于细菌群落趋药性优化的最小二乘支持向量机短期负荷预测方法[J].中国电机工程学报,2011,31(34):93-99.  
ZENG Ming, LÜ Chunquan, TIAN Kuo, et al. Least squares-support vector machine load forecasting approach optimized by bacterial colony chemotaxis method [J]. Proceedings of the CSEE, 2011, 31(34): 93-99.
- [8] 何耀耀,刘瑞,撒奥洋.基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J].中国电机工程学报,2017,37(3):768-776.  
HE Yaoyao, LIU Rui, HAN Aoyang. Short-term power load probability density forecasting method based on real time price and support vector quantile regression [J]. Proceedings of the CSEE, 2017, 37(3): 768-776.
- [9] 邹政达,孙雅明,张智晟.基于蚁群优化算法递归神经网络的短期负荷预测[J].电网技术,2005,29(3):59-63.  
ZOU Zhengda, SUN Yaming, ZHANG Zhisheng. Short-term load forecasting based on recurrent neural network using ant colony optimization algorithm [J]. Power System Technology, 2005, 29(3): 59-63.
- [10] 李国庆,刘钊,金国彬,等.基于随机分布式嵌入框架及BP神经网络的超短期电力负荷预测[J].电网技术,2020,44(2):437-445.  
LI Guoqing, LIU Zhao, JIN Guobin, et al. Ultra short-term

- power load forecasting based on randomly distributive embedded framework and BP neural network [J]. Power System Technology, 2020, 44(2): 437-445.
- [11] 刘洋,许立雄.适用于海量负荷数据分类的高性能反向传播神经网络算法[J].电力系统自动化,2018,42(21):96-103.  
LIU Yang, XU Lixiong. High-performance back propagation neural network algorithm for classification of mass load data[J]. Automation of Electric Power Systems, 2018, 42(21): 96-103.
- [12] 苏学能,刘天琪,曹鸿谦,等.基于Hadoop架构的多重分布式BP神经网络的短期负荷预测方法[J].中国电机工程学报,2017,37(17):4966-4973.  
SU Xueneng, LIU Tianqi, CAO Hongqian, et al. A multiple distributed BP neural networks approach for short-term load forecasting based on Hadoop framework[J]. Proceedings of the CSEE, 2017, 37(17): 4966-4973.
- [13] 彭文,王金睿,尹山青.电力市场中基于Attention-LSTM的短期负荷预测模型[J].电网技术,2019,43(5):1745-1751.  
PENG Wen, WANG Jinrui, YIN Shanqing. Short-term load forecasting model based on Attention-LSTM in electricity market[J]. Power System Technology, 2019, 43(5): 1745-1751.
- [14] 陆继翔,张琪培,杨志宏,等.基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J].电力系统自动化,2019,43(8):131-137.  
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137.
- [15] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. generative adversarial nets[C]// Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014, Montreal, Canada.
- [16] 王静,邹慧敏,曲东东,等.基于经验模态分解生成对抗网络的金融时间序列预测[J].计算机应用与软件,2020,37(5):293-297.  
WANG Jing, ZOU Huimin, QU Dongdong, et al. Financial time series prediction based on empirical mode decomposition to generate adversarial networks[J]. Computer Applications and Software, 2020, 37(5): 293-297.
- [17] 杨玉莲,齐林海,王红,等.基于生成对抗和双重语义感知的配电网量测数据缺失重构[J].电力系统自动化,2020,44(18):46-54.  
YANG Yulian, QI Linhai, WANG Hong, et al. Reconstruction of missing measurement data in distribution network based on generative adversarial network and double semantic perception [J]. Automation of Electric Power Systems, 2020, 44(18): 46-54.
- [18] 黄文琦,许爱东,明哲,等.基于生成对抗网络的变电站工作人员行为预测的方法[J].南方电网技术,2019,13(2):45-50.  
HUANG Wenqi, XU Aidong, MING Zhe, et al. Prediction method for the behavior of substation staff based on generative adversarial network[J]. Southern Power System Technology, 2019, 13(2): 45-50.
- [19] 肖白,黄钰茹,姜卓,等.数据匮乏场景下采用生成对抗网络的空间负荷预测方法[J/OL].中国电机工程学报[2020-04-14].  
<https://kns-cnki-net.webvpn.las.ac.cn/kcms/detail/11.2107.TM.20200414.1255.007.html>.
- XIAO Bai, HUANG Yuru, JIANG Zhuo, et al. Spatial load forecasting method based on generated countermeasure network in data deficient scenario [J/OL]. Proceedings of the CSEE [2020-04-14]. <https://kns-cnki-net.webvpn.las.ac.cn/kcms/detail/11.2107.TM.20200414.1255.007.html>.
- [20] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: an overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [21] JOHNSON J, ALAHI A, LI F F. Perceptual losses for real-time style transfer and super-resolution [C]// Proceedings of the 14th European Conference on Computer Vision, October 11-14, 2016, The Netherlands.
- [22] 谭本东,杨军,赖秋频,等.基于改进CGAN的电力系统暂态稳定评估样本增强方法[J].电力系统自动化,2019,43(1):149-157.  
TAN Bendong, YANG Jun, LAI Qiupin, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network [J]. Automation of Electric Power Systems, 2019, 43(1): 149-157.
- [23] 袁福来,戴宁,田素坤,等.采用条件生成式对抗网络的缺损牙全冠修复技术[J].计算机辅助设计与图形学学报,2019,31(12):2113-2120.  
YUAN Fulai, DAI Ning, TIAN Sukun, et al. A full crown restoration approach for defect teeth based on CGAN [J]. Journal of Computer-aided Design & Computer Graphics, 2019, 31(12): 2113-2120.
- [24] 李昭显,艾芊,张宇帆,等.基于attention机制的LSTM神经网络超短期负荷预测方法[J].供用电,2019,36(1):17-22.  
LI Zhaoyu, AI Qian, ZHANG Yufan, et al. A LSTM neural network method based on attention mechanism for ultra short-term load forecasting [J]. Distribution & Utilization, 2019, 36(1): 17-22.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [26] 查雪帆,杨丰,吴俣南,等.结合迁移学习与深度卷积网络的心电分类研究[J].中国医学物理学杂志,2018,35(11):1307-1312.  
ZHA Xuefan, YANG Feng, WU Yunan, et al. ECG classification based on transfer learning and deep convolution neural network[J]. Chinese Journal of Medical Physics, 2018, 35(11): 1307-1312.
- [27] 胡涛,张超,程炳,等.卷积神经网络在异常声音识别中的研究[J].信号处理,2018,34(3):357-367.  
HU Tao, ZHANG Chao, CHENG Bing, et al. Research on abnormal audio event detection based on convolutional neural networks [J]. Journal of Signal Processing, 2018, 34(3): 357-367.
- [28] ZEILER M D, TAYLOR G W, FERGUS R. Adaptive deconvolutional networks for mid and high level feature learning [C]// 2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain.
- [29] NAIR V, HINTON G E. Rectified linear units improve

restricted Boltzmann machines [C]// Proceedings of the 27th International Conference on Machine Learning, June 21-24, 2010, Haifa, Israel: 807-814.

林 珊(1995—),女,硕士研究生,主要研究方向:深度学习、电力大数据处理。E-mail:linshan@ncepu.edu.cn

王 红(1978—),女,通信作者,博士,讲师,主要研究方

向:大数据应用技术、电能质量智能信息处理。E-mail:wh@ncepu.edu.cn

齐林海(1964—),男,副教授,主要研究方向:电能质量智能信息处理、智能电网大数据应用。E-mail:qilinhai@ncepu.edu.cn

(编辑 鲁尔姣)

## Short-term Load Forecasting Based on Conditional Generative Adversarial Network

LIN Shan, WANG Hong, QI Linhai, FENG Hanyu, SU Ying

(School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

**Abstract:** Accurate short-term load forecasting is of great significance for power systems to formulate rational production plans, improve economic benefits, and ensure safe operation of power grids. In order to learn the hidden deep relationship in nonlinear load data and improve the accuracy of the short-term load forecasting, this paper proposes a short-term load forecasting model based on the conditional generative adversarial network. This model uses the convolutional neural network to construct a generative model and a discriminant model, which takes load influencing factors as conditions, and introduces a feature loss function as the loss function of some hidden layers in the discriminant model. Through the game training of the conditional generative adversarial network, the generative model takes the load influencing factors as the conditions to generate the forecasting load data, and then performs short-term load forecasting. Finally, taking the three-year load in a certain area of the United States as a practical example, the forecasting results of the proposed model are compared with other models. It is verified that the proposed model can improve the accuracy of the short-term load forecasting while considering the generalization ability.

**Key words:** conditional generative adversarial network; load data; short-term load forecasting; convolutional neural network

