DOI：10.13890/j.issn.1000-128X.2023.02.017
文章编号：1000-128X(2023)02-0142-09

电气化铁路牵引负荷预测研究

刘　福[1]，廖启术[2]
（1.国家能源投资集团 朔黄铁路发展有限责任公司，河北 肃宁　062350；
2.株洲中车时代电气股份有限公司，湖南 株洲　412001）

摘　要：为保证牵引供电系统电能质量并减少牵引变电所购电成本，文章提出了一种基于稀疏高斯过程（sparse Gaussian process, SGP）的牵引负荷概率预测模型。该模型首先构建以牵引负荷历史特征和时间信息为基础的输入特征向量；然后建立输入特征到牵引负荷之间的映射关系，并用SGP来拟合该映射关系；最后使用滚动预测的形式来实现对牵引负荷的预测。在朔黄铁路某牵引变电所实际运行数据上进行的对比试验验证了所提方法的优越性，其中，点预测可以得到误差在7%左右的预测值，概率预测可以得到不同置信度下可靠的预测区间。

关键词：牵引负荷；负荷预测；高斯过程；点预测；概率预测；电力机车
中图分类号：U223　　**文献标识码：**A

Research on traction load forecasting of electrified railway

LIU Fu[1], LIAO Qishu[2]

（1. Shuohuang Railway Development Co., Ltd., CHN ENERGY, Suning, Hebei 062350, China；
2. Zhuzhou CRRC Times Electric Co., Ltd., Zhuzhou, Hunan 412001, China）

Abstract: In order to ensure the power quality of traction power supply system and reduce the costs for purchasing electricity by traction substation, a probabilistic forecasting model of traction load based on sparse Gaussian process (SGP) is proposed. Firstly, the model constructed the input feature vector based on the historical characteristics of traction load and time information. Then, the mapping relationship between input characteristics and traction load was established, and SGP was used to fit the mapping relationship. Finally, a rolling forecasting methodology was used to predict the traction load. The comparative experiments carried out on the real operation data of a traction substation on Shuohuang railway verify the advantage of the proposed method, where the point forecasting can obtain the prediction value with an error of about 7%, and the probabilistic forecasting can obtain the reliable prediction interval under different confidence coefficients.

Keywords: ttraction load; load forecasting; Gaussian process; point forecasting; probabilistic forecasting; electric locomotive

0　引言

国家“十四五”铁路发展规划指出，我国在“十四五”期间要统筹中西部地区铁路建设，继续全面推进铁路向高质量方向发展。铁路作为我国重要的基础设施，承担着保障交通运输和保障民生需求的重任。铁路电气化作为我国能源结构转型的重要组成部分，近些年来得到了飞速发展，在客运与货运机车以及城市轨道交通方面都有着全方位的应用，以高铁、动车为代表的铁路运输已经成为我国陆路运输系统的主要组成部分[1]。

电力机车负荷作为大功率单体负荷，具有不确定性强、波动性大、动态性强的特点。当电力机车在牵引工况和再生工况进行切换时，牵引负荷会对电网产生负序、谐波等负面影响，进而影响电网的电能质

通信作者：廖启术（1998—），男，硕士，主要从事电力机车PHM方面的研究；E-mail: lqslqsuestc@163.com
引用格式：刘福, 廖启术. 电气化铁路牵引负荷预测研究[J]. 机车电传动, 2023(2): 142-150.
Citation：LIU Fu, LIAO Qishu. Research on traction load forecasting of electrified railway[J]. Electric Drive for Locomotives,2023(2): 142-150.

量[2]。另外，为了保障电力系统的稳定运行和经济调度，国家电网公司要求铁路运营部门对每个牵引变电所购买的电量进行准确预测，若预测误差大于 10%，国家电网公司将对超出电量按高于直购电价的价格进行结算，因此会导致电费支出增加，运营成本增大[3]。准确的牵引负荷预测可以解决上述问题，一方面为合理分配牵引负荷能量提供依据，提升电能质量[4]；另一方面给铁路运营公司带来经济效益，降低生产运营成本。

负荷预测在电力系统中发展了很多年，目前应用较广泛的负荷预测方法有人工神经网络（artificial neural network, ANN）[5-7]、线性回归（linear regression, LR）、支持向量回归（support vector regression, SVM）[8]、长短期记忆网络（long short term memory, LSTM）[9]等。上述方法都属于点预测方法（确定性预测），即对每个时间点给出一个确定性的预测值[10]。然而，随着电动汽车等随机性较强的新能源负荷接入电力系统，传统的点预测难以满足负荷预测的需求。因此，负荷概率预测在近些年成为了研究热点，概率预测可以给出预测点的预测区间或概率密度函数，为负荷不确定性提供参考信息。文献[11]提出了一种基于 LSTM 分位数回归的短期负荷概率预测方法，所提方法取得了更高的预测效率和更可靠的概率预测结果。文献[12]提出了一种基于改进极限学习机的负荷概率预测方法，该方法可避免算法陷入局部最优解，在湖南省某市电力负荷上的验证试验表明所提方法可以得到准确的预测区间。文献[13]提出了一种针对海量用户的负荷分层概率预测模型，对用户进行精细化用电管理，试验表明所提方法具有可行性和优越性。

虽然负荷预测在电力系统领域已经取得较多成果，但是牵引负荷由于波动性大、随机性强而较难预测，因此不能直接将电力系统负荷预测的方法应用到牵引负荷预测中。目前牵引负荷预测主要分为 2 类：一种是基于牵引计算和供电计算的仿真预测，另一种是基于实测数据的负荷预测[14]。其中，基于仿真计算的牵引负荷预测方法取得了较多的研究成果，如：文献[15]通过构建列车牵引计算模块和牵引供电系统潮流计算模块来实现对牵引变电所馈线电流的仿真计算，并成功地仿真了某条线路牵引变电所馈线电流的变化过程；文献[16]提出了一种列车能耗计算方法，该方法综合考虑了机车性能、线路属性等因素对列车牵引能耗的影响，试验结果表明，所提方法能够得到列车牵引能耗的变化结果，然而，基于仿真计算的方法适用于较为稳定的铁路线路牵引负荷预测，在受到新建线路或行车随机因素等影响时其预测准确度会降低。随着机车运行时间的增加，牵引负荷的实测数据越来越多，基于实测数据的牵引负荷预测方法应运而生，这类方法通过分析大量实测数据然后建立牵引负荷模型以求得牵引负荷预测值。文献[17]基于负荷功率和谐波电流之间的相关性，使用非参数估计方法，建立了各次谐波电流的概率分布模型，试验结果表明了所建模型的有效性。文献[18]通过对牵引负荷的分布特征进行研究，结合抽样方法获取样本数据来实现牵引负荷预测。基于实测数据的预测方法大多以日/周/月为周期进行预测[2]，预测时间跨度较大，因此急需研究一种可以反映牵引负荷实时变化状态的预测方法。

近些年来，基于高斯过程（Gaussian process, GP）的负荷预测模型得到了发展[19-21]。GP 是一种非参数化模型，GP 的训练过程可以视为求解从输入到输出的概率分布的过程，由于不需要事先设定网络结构和参数，GP 的使用更灵活，可以避免出现过拟合的现象。另外，基于 GP 的负荷预测方法通过构建一个可靠的 GP 模型，在用大量历史实测数据进行训练后，可以通过训练后的 GP 模型得到牵引负荷的实时预测值。然而，高斯过程的训练复杂度较高，当训练样本较多时训练时间过长，稀疏高斯过程（sparse Gaussian process, SGP）使用变分分布来近似 GP 分布，可以降低模型训练复杂度，缩短训练时间。因此本文提出了一种基于 SGP 的牵引负荷概率预测模型，该非参数化模型可以避免训练过程中的过拟合现象，攻克了在牵引负荷波动性较大、随机性较强背景下牵引负荷难以精确预测的难题，实现了对牵引负荷实时变化状态的评估。采用该模型不仅能得到未来时刻的牵引负荷预测值，给出一个确定性预测结果，而且能得到牵引负荷的概率预测结果，并以区间预测的形式呈现，为评估牵引负荷的不确定性提供参考信息。

1　算法理论

1.1　高斯过程

假设有 N 组训练数据集 $\{\boldsymbol{X},\boldsymbol{Y}\}$，其中：$\boldsymbol{X}=[x_1,x_2,\cdots,x_N]^{\mathrm{T}}$ 和 $\boldsymbol{Y}=[y_1,y_2,\cdots,y_N]^{\mathrm{T}}$ 分别代表训练输入特征和训练输出（牵引负荷），则有：

$$\boldsymbol{Y}=g(\boldsymbol{X})+\boldsymbol{\varepsilon} \tag{1}$$

式中：$g(\boldsymbol{X})$ 为输入到输出的映射关系，可以视为一个高斯过程；$\boldsymbol{\varepsilon}$ 为高斯白噪声。

根据式(1)得出

$$g(\boldsymbol{X})\sim\mathrm{GP}(m(\boldsymbol{X}),K(\boldsymbol{X},\boldsymbol{X})) \tag{2}$$

式中：$g(\boldsymbol{X})$ 为均值为 $m(\boldsymbol{X})$、协方差矩阵为 $K(\boldsymbol{X},\boldsymbol{X})$ 的高斯过程（在无过多先验知识时，一般取零均值）。

当取零均值高斯过程时，先验分布为：

$$p(\boldsymbol{Y}|\boldsymbol{X})=N(\boldsymbol{0},K(\boldsymbol{X},\boldsymbol{X})+\sigma_n^2\boldsymbol{I}) \tag{3}$$

式中：σ_n^2 为高斯白噪声 $\boldsymbol{\varepsilon}$ 的方差；$\boldsymbol{I}$ 为 N 维单位矩阵；$K(\boldsymbol{X},\boldsymbol{X})$ 为训练输入之间的 $N\times N$ 维协方差矩阵。

在测试阶段，输入新的测试点 x^* 即可得到预测值

$g(x^*)$，训练数据集$\{\boldsymbol{X},\boldsymbol{Y}\}$和测试数据$(x^*,y^*)$之间存在关联：

$$\begin{pmatrix}\boldsymbol{Y}\\ g(x^*)\end{pmatrix}\sim N\left[\begin{pmatrix}\boldsymbol{0}\\ \boldsymbol{0}\end{pmatrix},\begin{pmatrix}K(\boldsymbol{X},\boldsymbol{X})+\sigma_n^2\boldsymbol{I} & K(\boldsymbol{X},x^*)\\ K(x^*,\boldsymbol{X}) & K(x^*,x^*)\end{pmatrix}\right] \tag{4}$$

其中，$K(\cdot)$代表协方差矩阵。可以根据训练数据和测试数据之间的关联求解出测试点x^*的回归均值$\bar{g}(x^*)$和方差$\mathrm{cov}(g(x^*))$，即：

$$\bar{g}(x^*)=K(x^*,\boldsymbol{X})(K(\boldsymbol{X},\boldsymbol{X})+\sigma_n^2\boldsymbol{I})^{-1}\boldsymbol{Y} \tag{5}$$

$$\mathrm{cov}(g(x^*))=K(x^*,x^*)-K(x^*,\boldsymbol{X})(K(\boldsymbol{X},\boldsymbol{X})+\sigma_n^2\boldsymbol{I})^{-1}K(\boldsymbol{X},x^*) \tag{6}$$

式中：$K(\boldsymbol{X},x^*)$和$K(x^*,\boldsymbol{X})$分别为训练输入和测试点之间的$N\times 1$和$1\times N$维协方差矩阵；$K(x^*,x^*)$为测试点的协方差。

各协方差矩阵的元素$k(\cdot)$为：

$$k\left(x_i,x_j\right)=\sigma_{\mathrm{ard}}^2\exp\left(-\frac{1}{2}\left(x_i-x_j\right)^2\right) \tag{7}$$

式中：σ_{ard}为协方差参数。

1.2 稀疏高斯过程

由于高斯过程在训练过程中涉及到训练数据集$(\boldsymbol{X},\boldsymbol{Y})$的逆运算，其训练复杂度为$O(N^3)$，因此高斯过程在大样本应用场景中，存在训练时间过长的弊端，为了降低训练复杂度，缩短训练时间，一般通过引用M个辅助点（$M\ll N$）来将训练复杂度降低到$O(NM^2)$，即稀疏高斯过程（SGP）。

SGP引入辅助输入$\boldsymbol{Z}=[z_1,z_2,\cdots,z_M]^{\mathrm{T}}$和对应的辅助输出$\boldsymbol{u}=[u_1,u_2,\cdots,u_M]^{\mathrm{T}}$来近似GP中的高维高斯过程。SGP的联合概率密度为

$$p\left(\boldsymbol{Y},\boldsymbol{f},\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z}\right)=p\left(\boldsymbol{Y}|\boldsymbol{f}\right)p\left(\boldsymbol{f},\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z}\right) \tag{8}$$

式中：$p\left(\boldsymbol{Y}|\boldsymbol{f}\right)$为似然；$\boldsymbol{f}$为$N$维高斯过程无噪声输出；$p\left(\boldsymbol{f},\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z}\right)$为联合高斯后验分布且可被分解为先验分布$p(\boldsymbol{u})$和条件分布$p(\boldsymbol{f}|\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z})$。

引入变分先验$q(\boldsymbol{u})=N(\boldsymbol{\mu},\Sigma)$来近似先验分布$p(\boldsymbol{u})$，则有变分后验分布$q(\boldsymbol{u},\boldsymbol{f})=p(\boldsymbol{f}|\boldsymbol{u})q(\boldsymbol{u})$。变分推断通过最小化变分后验$q(\boldsymbol{u},\boldsymbol{f})$和真实后验$p(\boldsymbol{u},\boldsymbol{f})$之间的Kullback-Leibler（KL）散度来优化参数，等价于最大化模型证据下界（Evidence Lower Bound, ELBO）：

$$\lg\ p(\boldsymbol{Y})\geqslant E_{q(\boldsymbol{u},\boldsymbol{f})}\lg\frac{p\left(\boldsymbol{Y},\boldsymbol{f},\boldsymbol{u}\right)}{q\left(\boldsymbol{u},\boldsymbol{f}\right)} \tag{9}$$

式(9)中的联合概率密度$p\left(\boldsymbol{Y},\boldsymbol{f},\boldsymbol{u}\right)$由式(8)得到，则可得到高斯边缘似然：

$$q\left(\boldsymbol{f}\right)=\int p\left(\boldsymbol{f}|\boldsymbol{u}\right)q(\boldsymbol{u})\mathrm{d}\boldsymbol{u} \tag{10}$$

ELBO简化后为：

$$L_{\mathrm{SGP}}\geqslant\lg\ p(\boldsymbol{Y})\geqslant E_{q(\boldsymbol{f})}\lg\ p\left(\boldsymbol{Y}|\boldsymbol{f}\right)-KL\left(q(\boldsymbol{u})\|p(\boldsymbol{u})\right) \tag{11}$$

式(11)中的函数$KL(\cdot)$指KL散度函数。由于上式各项均为已知，则可以通过最大化式(11)的ELBO来优化SGP的各项模型参数：

$$\theta_{\mathrm{SGP}}=\left\{\boldsymbol{\mu},\Sigma,\boldsymbol{Z},\sigma_{\mathrm{ard}},\sigma_n\right\} \tag{12}$$

在得到变分参数$\boldsymbol{\mu}$和Σ之后，即可利用最优变分先验分布$q(\boldsymbol{u})=N\left(\boldsymbol{\mu},\Sigma\right)$来对新测试点$x^*$进行预测并得到对应的测试输出$g(x^*)$。

1.3 预测模型

本文主要针对电气化铁路上某一供电区域内牵引负荷消耗进行预测，因此本文所指负荷可以视作某一供电区域内牵引变电站需要提供的牵引负荷。牵引负荷按时间序列可表示为$\{P_t\}$，在进行负荷预测时，为了得到下一时刻的负荷消耗，需要先通过历史数据建立从输入特征到输出变量的映射关系，然后在预测时将待预测时刻的输入特征输入到建立的映射关系中即可求得待预测时刻的负荷预测值，即：

$$f\left(x_{t-H},\cdots,x_t\right)=\left\{P_{t-H},\cdots,P_t\right\} \tag{13}$$

$$f\left(x_{t+1}\right)=P_{t+1} \tag{14}$$

式中：H是历史数据的样本数，代表使用了H+1组数据进行训练；x是输入特征，一般包括历史特征、时间信息、机车特征信息等；f是输入到输出之间的映射关系，一般用神经网络等机器学习算法来求解，本文中则使用SGP来求解。

式(13)代表训练过程，在该过程中，主要使用H+1组历史数据来对构建的映射关系进行训练，找到合适的模型来拟合输入输出之间的关系；式(14)代表预测过程，在该过程中，将待预测时刻的输入特征输入到式(13)求解的预测模型中，即可求解出待预测时刻的负荷。

图1为本文提出的基于SGP的牵引负荷预测模型，首先，从牵引供电系统中获取某段供电区域内牵引变电站的牵引负荷数据；然后，从牵引负荷数据中提取历史特征数据并结合时间信息构成SGP预测模型的输入特征；最后，将待预测时刻的输入特征输入到被历史数据训练后的SGP预测模型即可得到待预测时刻的牵引负荷预测结果。

2 输入特征与评估方法

2.1 输入特征

图2为本文使用的一种连续滚动预测模型，即用前n个时刻的历史负荷和待预测时刻的时间信息作为输入特征，求解与待预测时刻负荷之间的映射关系。

具体的输入特征可以分为历史特征和时间信息，以图1中预测t时刻负荷为例，该时刻的历史特征为从$t-n$时刻到$t-1$时刻间的n组数据（本文中n取10）；时间信息则是t时刻的秒钟s、分钟m、小时h等信息。具体可以表示为：

$$X_t=\left[P_{t-n},\cdots,P_{t-1},s_t,m_t,h_t\right] \tag{15}$$

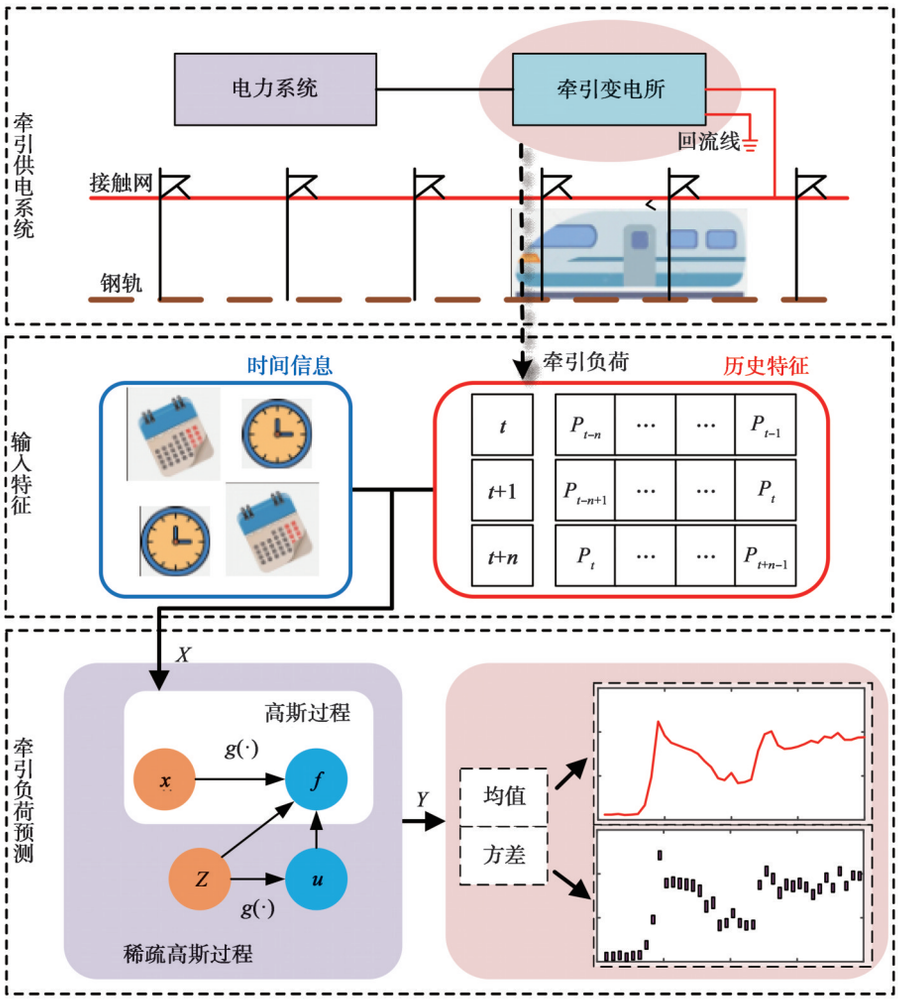

图 1　基于 SGP 的牵引负荷预测模型框架

Fig. 1　Framework of traction load forecasting model based on SGP

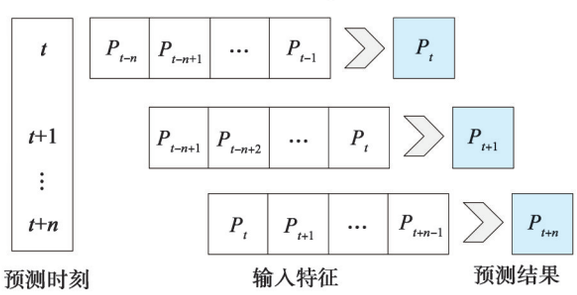

图 2　滚动负荷预测模型

Fig. 2　Prediction model of rolling load

式中：X_t表示 t 时刻的输入特征；s_t表示 t 时刻的秒钟信息；m_t表示 t 时刻的分钟信息；h_t表示 t 时刻的小时信息。

综上可得到，每个时刻的输入信息共有 n+3 维。对于某一时刻 t 的输入特征有对应的输出 Y_t 即该时刻的真实负荷值 P_t，则选取两个数据集分别为训练集 $P^{\mathrm{tr}}=\{X^{\mathrm{tr}}, Y^{\mathrm{tr}}\}$ 和测试集 $P^{\mathrm{ts}}=\{X^{\mathrm{ts}}, Y^{\mathrm{ts}}\}$。

2.2　评估方法

2.2.1　点预测评估指标

为了验证本文所提方法的点预测有效性，检验预测值和真实值之间的预测误差，本文使用了 3 种点预测评估指标，即均方根误差（root mean squared error, RMSE）、平均绝对误差（mean absolute error, MAE）和平均绝对百分比误差（mean absolute percentage error, MAPE）。本文中用 Q^{r}、Q^{m} 和 Q^{a} 分别代表 RMSE、MAE 和 MAPE 3 种评估指标，计算公式见式(16)~式(18)。

$$Q^{\mathrm{r}}=\sqrt{\frac{1}{H}\sum_{h=1}^{H}\left(\bar{y}_h-y_h\right)^2} \tag{16}$$

$$Q^{\mathrm{m}}=\frac{1}{H}\sum_{h=1}^{H}\left|\bar{y}_h-y_h\right| \tag{17}$$

$$Q^{\mathrm{a}}=\frac{100\%}{H}\sum_{h=1}^{H}\left|\frac{\bar{y}_h-y_h}{y_h}\right| \tag{18}$$

式中：H 指预测总数；$\bar{y}$ 指预测值；y 指真实值。

Q^{r}、Q^{m} 和 Q^{a} 可以反映出预测值和真实值之间的偏差，经常用在预测或其他机器学习领域，在本文中，Q^{r} 和 Q^{m} 的单位均为 MW，Q^{a} 单位为%。

2.2.2　概率预测评估指标

为了验证所提方法的概率预测效果，本文使用了 2 种概率预测指标，分别为 Winkle 指标和 PINAW 指标，本文用 Q^{w} 和 Q^{p} 分别表示 Winkler 指标和 PINAW 指标。

Q^{w}可以表示如下：

$$Q^{\mathrm{w}}=\begin{cases}\left(U_{t,\alpha}-L_{t,\alpha}\right)+2\left(L_{t,\alpha}-y_t\right)/\alpha, & \text{if } y_t<L_{t,\alpha}\\ U_{t,\alpha}-L_{t,\alpha}, & \text{if } L_{t,\alpha}\leqslant y_t\leqslant U_{t,\alpha}\\ \left(U_{t,\alpha}-L_{t,\alpha}\right)+2\left(y_t-L_{t,\alpha}\right)/\alpha, & \text{if } y_t>U_{t,\alpha}\end{cases} \tag{19}$$

式中：$\alpha=0.01,0.02,\cdots,0.99$，代表不同的分位数，如$\alpha$为0.1时，代表取置信度为$(1-\alpha)\times100\%$即90%预测区间；$U_{t,\alpha}$、$L_{t,\alpha}$分别指$t$时刻分位数为$\alpha$时预测区间的上下界；$y_t$为$t$时刻的实际值。

Q^{w}通过预测区间的宽度和准度来评估区间预测的效果，即当某个时刻的预测区间不包含真实值时，对评估结果施以惩罚。Q^{w}值越小代表概率预测效果越好。

Q^{p}指标主要用于评估预测区间的宽度，可表示如下：

$$Q^{\mathrm{p}}=\frac{1}{TR}\sum_{t=1}^{T}\left(U_{t,\alpha}-L_{t,\alpha}\right) \tag{20}$$

式中：R为实际值中最大值与最小值的差值；$U_{t,\alpha}$、$L_{t,\alpha}$分别指t时刻分位数为α时预测区间的上下界。

Q^{p}的值越小代表预测区间越窄，预测效果越好。

2.2.3 评估流程

图3为本文预测结果评估流程，首先，通过训练数据$(\boldsymbol{X},\boldsymbol{Y})$对预测模型SGP进行训练；然后，将待预测时刻的输入特征x^*输入到训练后的预测模型SGP中，即可得到该时刻的预测值$\bar{y}^*$；最后，将$\bar{y}^*$和待预测时刻的真实负荷y^*输入评估系统，即可求得反映真实值和预测值偏差的点预测评估指标和概率预测评估指标。

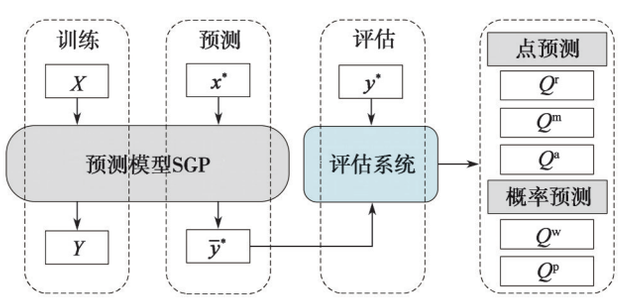

图3 预测结果评估流程

Fig. 3 Evaluation process of forecasting results

3 算例分析

3.1 数据设置

以朔黄铁路某牵引变电站的实际运行工况数据为基础进行试验，使用数据为某天10时至13时3个小时的数据量，在这个时段内每300 ms对区域内所有列车运行状态进行一次采样得到多组负荷数据。由于列车在短时间内运行状态变化较小，为了更好地体现本文所提方法的预测效果，对该数据进行了再采样，得到了每3 s采样一次的数据共4 000组，并从中选取了2 000组数据作为训练集，选取200组数据作为测试集。由于本文使用的是连续滚动预测方法，即预测第t时刻的负荷时，使用前n个时刻（本文中n=10）的历史负荷和第t时刻的时间信息作为输入特征，求解与第t时刻负荷之间的映射关系。任意选取H组数据进行训练，都应能得到理想的预测结果。另外，考虑到实际应用场景中训练数据是不固定的，因此本文中的训练数据为从4 000组数据中随机挑选的2 000组连续数据，测试数据为与训练集不同的另外200组连续数据。

3.2 点预测结果

为了验证所提方法在点预测上的优越性，选取了几种其余常用于负荷预测的机器学习算法作为对比，包括线性回归（linear regression, LR）、支持向量回归（support vector regression, SVR）和反向传播神经网络（back-propagation neural, BPN）。

为了对比不同方法的点预测效果，使用连续的2 000组训练数据来对各个模型进行训练，然后都在相同的连续200组共10 min的测试数据集上进行测试试验，其中，试验所用数据为3.1节所描述来自朔黄铁路的实际运行数据。表1为不同模型在测试集上的Q^{r}、Q^{m}和Q^{a}3个指标的对比结果。

表1 4种方法的点预测结果对比

Table 1 Comparison of point forecasting results using four methods

方法	Q^{r}/MW	Q^{m}/MW	Q^{a}
SVR	4.642	4.642	37.28%
LR	3.897	2.085	14.80%
BPN	3.601	1.988	13.18%
SGP	2.582	1.888	7.49%

从表1可以看到，使用不同的预测方法得到的牵引负荷预测结果有较大不同，其中，SVR的预测效果最差，在Q^{r}、Q^{m}和Q^{a}3种指标上均远大于另外3种预测方法。本文所提的基于SGP的预测模型的预测效果远好于另外3种，相比于效果较差的SVR，SGP在Q^{r}、Q^{m}和Q^{a}3种指标上分别提升了44.37%、59.33%和79.91%；相比于在预测回归方面有较多应用场景且在本文牵引负荷预测中有着较好预测效果的BP相比，SGP在Q^{r}、Q^{m}和Q^{a}3个指标上分别提升了28.30%、5.03%和43.17%。从评估指标角度来看，本文所提方法的预测效果远远优于其他的预测方法，且其误差指标MAPE可以达到7%左右，符合国家电网公司要求铁路运营部门将牵引负荷预测准确率控制在10%以内的要求，证明了采用本文所提方法可以得到精确的牵引负荷预测结果。

为了更直观地了解所提方法的预测结果并对比几种不同模型的预测效果，图4绘制了测试集前5 min的牵引负荷预测效果。从图4可以看到，在5 min内该供电区域内机车的负荷状态发生了较大、较快的变化，

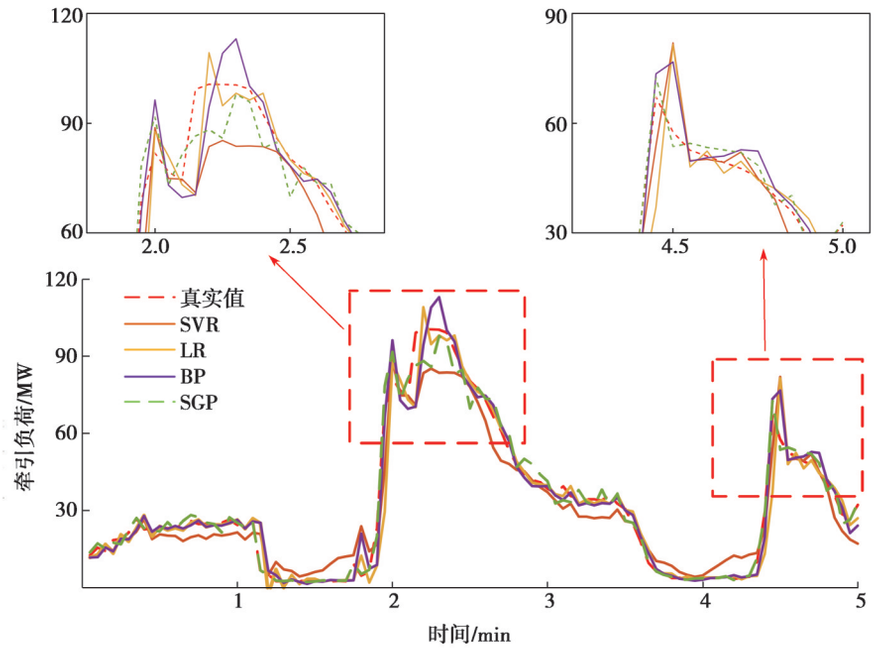

图 4　所有模型预测结果对比

Fig. 4　Comparison of forecasting results of all models

说明实际工作中的负荷会随机车运行工况的变化发生较快的变化，进一步说明了对牵引负荷进行准确的预测是很有必要的，既可以确保机车的电能质量，避免对机车以及电网的安全运行造成威胁，又能给牵引变电站规划供电方案、保障不同列车用电需求提供参考信息。

从图 4 的对比图中，可以看到 SVR 的预测结果始终与真实值存在较大偏差，也对应了表 1 中 SVR 的 3 个评估指标均远大于其他几种模型的预测结果，说明了 SVR 不适合用于解决机车的负荷预测问题。另外，从图 4 中放大的 2 处对比结果可以看到，在 2.2 min 附近和 4.5 min 附近 2 段负荷峰值阶段，可以看到所提模型 SGP 预测结果与真实值拟合得最好。负荷峰值代表该时刻区域内处于高速运行状态的列车较多，此刻对用电的稳定和安全要求更高，因此，所提方法在峰值的预测效果说明了 SGP 能够在牵引变电站供电区域内列车用电高峰期依然提供可靠的预测结果。

综合表 1 的评估指标对比和图 4 的点预测结果对比，可以看到本文所提方法能够提供可靠的牵引负荷预测结果且其预测效果远优于其他预测模型。

3.3　概率预测结果

为了验证本文所提方法的概率预测效果，选取分位数回归（quantile regression, QR）作为对比进行对照试验。训练集与测试集选取 3.1 节相同的数据，表 2 为 QR 与 SGP 在几种不同的置信度下得到的 Q^{w} 和 Q^{p} 指标结果。

从表 2 概率指标对比结果可以看到，在同一置信度的预测区间下，SGP 的 Q^{w} 指标和 Q^{p} 指标均小于 QR。其中，当分位数 α 为 0.05 即 95% 预测区间时，SGP 在 Q^{w} 和 Q^{p} 指标上比 QR 分别提升了 64.58% 和 72.47%；当分位数 α 为 0.2 即 80% 预测区间时，SGP 在 Q^{w} 和 Q^{p} 指标上比 QR 分别提升了 43.23% 和 40.16%；当分位数 α 为 0.3 即 70% 预测区间时，SGP 在 Q^{w} 和 Q^{p} 指标上比 QR 分别提升了 30.58% 和 37.11%；当分位数 α 为 0.4 即 60% 预测区间时，SGP 在 Q^{w} 和 Q^{p} 指标上比 QR 分别提升了 30.24% 和 22.96%。Q^{w} 指标评估的是每个时刻预测区间的宽度和准度，Q^{p} 评估的是整体预测区间的宽度，SGP 在这 2 种指标上均优于 QR，说明 SGP 的预测区间准确度更高，可以在确保预测区间包含真实值的前提下得到更窄的预测区间。

表 2　QR 与 SGP 的概率预测结果对比

Table 2　Comparison of probability forecasting results of QR and SGP

概率评估指标	方法	置信区间			
		95%	80%	70%	60%
Q^{w}	QR	6.967×10^{3}	3.162×10^{3}	2.279×10^{3}	2.034×10^{3}
	SGP	2.468×10^{3}	1.795×10^{3}	1.582×10^{3}	1.419×10^{3}
Q^{p}	QR	4.544×10^{-1}	1.569×10^{-1}	1.244×10^{-1}	8.124×10^{-2}
	SGP	1.251×10^{-1}	9.389×10^{-2}	7.824×10^{-2}	6.259×10^{-2}

另外，无论是 QR 还是 SGP，随着置信度的减小，即表 2 中每行从左至右数据，其评估指标 Q^{w} 和 Q^{p} 都是逐渐变小的，说明置信度越小，预测区间的宽度越窄，则预测区间包含真实值的可能性越低，预测区间的可靠度也越低。因此，更高置信度的预测区间往往更宽，更有把握包含真实值，表 2 中预测区间随置信度减小而变窄说明 QR 和 SGP 的区间预测是有效的。

图 5、图 6 分别为 2 种方法选取测试集中前 2 min 的

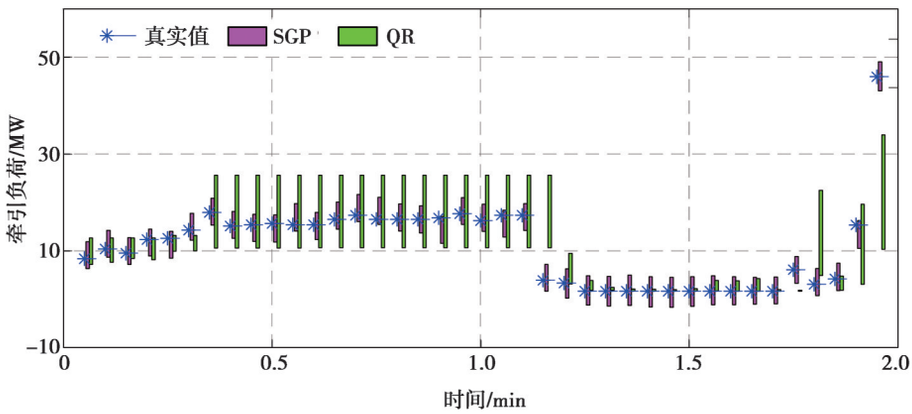

图5　QR与SGP的80%预测区间对比

Fig. 5　Comparison of QR and SGP with 80% forecasting interval

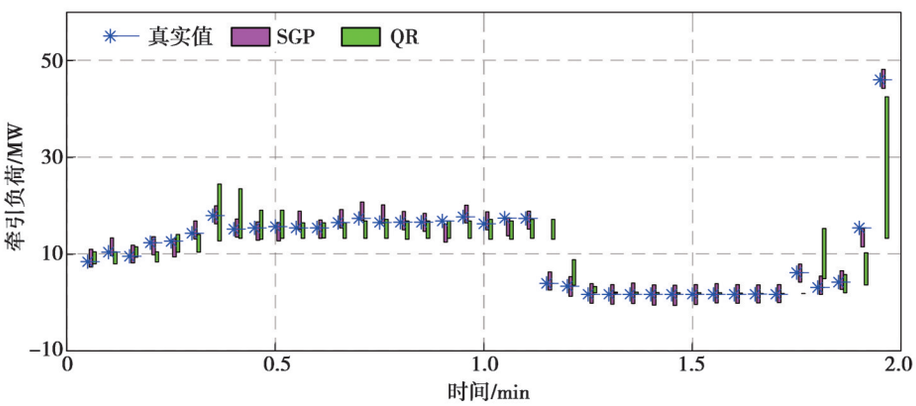

图6　QR与SGP的60%预测区间对比

Fig. 6　Comparison of QR and SGP with 60% forecasting interval

预测点在置信度为80%和60%时的预测区间对比图，更直观地比较了2种概率预测方法的区间预测效果。

从图5可知，在置信度为80%时，SGP的预测区间在所有时刻都包含了真实值，QR在部分时刻预测区间未包含真实值，表明SGP的区间预测可靠性高于QR。另外，SGP的预测区间在大部分时刻都比QR更窄，也说明SGP的区间预测效果更好。从图6可知，当置信度为60%时，虽然QR在大部分时刻的预测区间宽度都比SGP更窄，但是QR大部分时刻的真实值都在预测区间之外，表明QR是以牺牲预测可靠性来得到更窄的预测区间。结合表2中Winkler指标可看出，更窄的预测区间并不意味着预测效果更好，因此，综合看来，SGP的区间预测效果优于QR。

对比图5、图6可知，当置信度减小时，QR与SGP的预测区间都在变窄，预测区间包含真实值的可靠度越低，其中，QR在很多时刻的预测区间都不再包含真实值，SGP在个别时刻的预测区间不再包含真实值，说明了在得到区间预测结果后，要综合不同置信度下的预测区间对概率预测结果进行选择。

综合概率预测的评估指标和预测结果图可得，采用SGP可以得到有效的区间预测结果且其区间预测效果优于QR。

4　结论

本文提出了一种基于SGP的牵引负荷概率预测模型，通过构建输入特征和牵引负荷之间的映射关系，当输入待预测时刻的特征向量时可以获得该时刻的负荷预测结果。通过在某牵引变电所实际运行数据上的仿真试验结果可以看到，所提方法可以得到精确的点预测结果以及可靠的区间预测结果，为牵引变电所制定电力调度计划提供可靠的参考信息，为铁路运营公司精确预测牵引负荷从而减少购电成本提供依据。另外，为了进一步提高预测的精确度，将来可以考虑添加列车运行图、牵引负荷分布特性等更多的输入特征来训练更精确的预测模型。

参考文献：

[1] 王红燕, 胡月星 . 铁路负荷对接触网电压质量影响分析[J]. 电气技术与经济, 2019(2): 45-47.
WANG Hongyan, HU Yuexing. Analysis of influence of railway load on catenary voltage quality[J]. Electrical Equipment and Economy, 2019(2): 45-47.

[2] 魏波 . 基于行车运行图的高速铁路牵引负荷预测方法研究[D]. 成都: 西南交通大学, 2020.

WEI Bo. Research on traction load forecasting method for high-speed railway traction substation based on train timetable[D]. Chengdu: Southwest Jiaotong University, 2020.

[3] 马蓉, 任强德, 张苏华, 等. 电气化铁路负荷电能质量监测评估分析[J]. 高压电器, 2014, 50(12): 79-82.
MA Rong, REN Qiangde, ZHANG Suhua, et al. Analysis on power quality monitoring and evaluation for electrical railway load[J]. High Voltage Apparatus, 2014, 50(12): 79-82.

[4] 彭伊爽. 基于牵引负荷预测的电气化铁路储能系统控制策略设计[D]. 湘潭: 湘潭大学, 2021.
PENG Yishuang. Control strategy design of electrified railway energy storage system based on traction load forecast [D]. Xiangtan: Xiangtan University, 2021.

[5] 肖白, 刘庆永, 牛强, 等. 基于元胞负荷特性分析的RBF神经网络空间负荷预测方法[J]. 电网技术, 2018, 42(1): 301-307.
XIAO Bai, LIU Qingyong, NIU Qiang, et al. A spatial load forecasting method based on RBF neural network and cellular load characteristics analysis[J]. Power System Technology, 2018, 42(1): 301-307.

[6] 吴云, 雷建文, 鲍丽山, 等. 基于改进灰色关联分析与蝙蝠优化神经网络的短期负荷预测[J]. 电力系统自动化, 2018, 42(20): 67-72.
WU Yun, LEI Jianwen, BAO Lishan, et al. Short-term load forecasting based on improved grey relational analysis and neural network optimized by bat algorithm[J]. Automation of Electric Power Systems, 2018, 42(20): 67-72.

[7] 占勇, 程浩忠, 丁屹峰. 自适应神经网络在短期负荷预测中的应用[J]. 上海交通大学学报, 2005(增刊1): 14-17.
ZHAN Yong, CHENG Haozhong, DING Yifeng. The application of adaptive neural network in short term load forecasting[J]. Journal of Shanghai Jiaotong University, 2005 (Suppl 1): 14-17.

[8] 赵佩, 代业明. 基于实时电价和加权灰色关联投影的SVM电力负荷预测[J]. 电网技术, 2020, 44(4): 1325-1332.
ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. Power System Technology, 2020, 44(4): 1325-1332.

[9] 陈振宇, 刘金波, 李晨, 等. 基于LSTM与XGBoost组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology, 2020, 44(2): 614-620.

[10] SUN Mingyang, ZHANG Tingqi, WANG Yi, et al. Using bayesian deep learning to capture uncertainty for residential net load forecasting[J]. IEEE Transactions on Power System, 2020, 35(1): 188-201.

[11] 李丹, 张远航, 杨保华, 等. 基于约束并行LSTM分位数回归的短期电力负荷概率预测方法[J]. 电网技术, 2021, 45(4): 1356-1363.
LI Dan, ZHANG Yuanhang, YANG Baohua, et al. Short time power load probabilistic forecasting based on constrained parallel-LSTM neural network quantile regression mode[J]. Power System Technology, 2021, 45(4): 1356-1363.

[12] 曾林俊, 许加柱, 王家禹, 等. 考虑区间构造的改进极限学习机短期电力负荷区间预测[J]. 电网技术, 2022, 46(7): 2555-2563.
ZENG Linjun, XU Jiazhu, WANG Jiayu, et al. Short-term electrical load interval forecasting based on improved extreme learning machine considering interval construction[J]. Power System Technology, 2022, 46(7): 2555-2563.

[13] 顾洁, 孟璐, 郑睿程, 等. 考虑集群辨识的海量用户负荷分层概率预测[J]. 电力系统自动化, 2021, 45(5): 71-78.
GU Jie, MENG Lu, ZHENG Ruicheng, et al. Load-stratified probability forecasting for massive users considering cluster identification[J]. Automation of Electric Power Systems, 2021, 45(5): 71-78.

[14] 张丽艳, 李群湛, 朱毅. 新建电气化铁路牵引负荷预测[J]. 西南交通大学学报, 2016, 51(4): 743-749.
ZHANG Liyan, LI Qunzhan, ZHU Yi. Prediction of traction load for new electrified railway[J]. Journal of Southwest Jiaotong University, 2016, 51(4): 743-749.

[15] 万庆祝, 吴命利, 陈建业, 等. 基于牵引计算的牵引变电所馈线电流仿真计算[J]. 电工技术学报, 2007, 22(6): 108-113.
WAN Qingzhu, WU Mingli, CHEN Jianye, et al. Simulating calculation of traction substation's feeder current based on traction calculation[J]. Transactions of China Electrotechnical Society, 2007, 22(6): 108-113.

[16] 薛艳冰, 马大炜, 王烈. 列车牵引能耗计算方法[J]. 中国铁道科学, 2007, 28(3): 84-87.
XUE Yanbing, MA Dawei, WANG Lie. Calculation method of energy consumption in train traction[J]. China Railway Science, 2007, 28(3): 84-87.

[17] 陈民武, 刘洋, 韩旭东, 等. 高速铁路牵引负荷谐波分布的非参数估计模型与预测评估[J]. 电网技术, 2017, 41(8): 2598-2603.
CHEN Minwu, LIU Yang, HAN Xudong, et al. Harmonic distribution modeling based on non-parametric estimation and harmonic prediction evaluation for high speed railway traction load[J]. Power System Technology, 2017, 41(8): 2598-2603.

[18] 石若颖, 张丽艳, 刘炜, 等. 考虑再生工况的电气化铁路牵引负荷统计预测[J]. 电气化铁道, 2018, 29(1): 14-20.
SHI Ruoying, ZHANG Liyan, LIU Wei, et al. Statistical prediction of electrified railway traction loads with consideration of regenerative braking operation condition[J]. Electric Railway, 2018, 29(1): 14-20.

[19] 宗文婷, 卫志农, 孙国强, 等. 基于改进高斯过程回归模型

的短期负荷区间预测[J]. 电力系统及其自动化学报, 2017, 29(8): 22-28.
ZONG Wenting, WEI Zhinong, SUN Guoqiang, et al. Short-term load interval prediction based on improved Gaussian process regression model[J]. Proceedings of the CSU-EPSA, 2017, 29(8): 22-28.

[20] 彭虹桥, 顾洁, 胡玉, 等. 基于混沌粒子群—高斯过程回归的饱和负荷概率预测模型[J]. 电力系统自动化, 2017, 41(21): 25-32.
PENG Hongqiao, GU Jie, HU Yu, et al. Forecasting model of saturated load based on chaotic particle swarm and optimization-Gaussian process regression[J]. Automation of Electric Power Systems, 2017, 41(21): 25-32.

[21] 刘升伟, 王星华, 鲁迪, 等. 基于改进高斯过程回归的短期负荷概率区间预测方法[J]. 电力系统保护与控制, 2020, 48(1): 18-25.
LIU Shengwei, WANG Xinghua, LU Di, et al. Electric load probabilistic interval prediction method based on improved Gaussian process regression[J]. Power System Protection and Control, 2020, 48(1): 18-25.

收稿日期：2022-11-07
修回日期：2023-03-01