

基于模糊支持向量核回归方法的短期峰值负荷预测

蒋 刚

(西南科技大学 制造科学与工程学院, 四川 绵阳 621010)

摘要: 分析了电力系统负荷预测目前采用的方法的不足; 在已有研究成果的基础上, 根据电网负荷的特点进一步完善了基于模糊支持向量的核回归方法; 与目前已有的方法, 如神经网络、卡尔曼滤波、最小绝对值参数估计、结合遗传算法的支持向量机、结合模糊小波技术的支持向量机等进行比较实验, 实验结果展示了几种方法的性能对比, 为该领域的研究提供了参考。

关键词: 电力系统; 负荷预测; 模糊逻辑; 支持向量机; 核函数

中图分类号: TM7/TP391 **文献标识码:** A

Short-term peak load forecasting based on fuzzy support vector kernel regression method

JIANG Gang

(School of Manufacturing Science and Engineering, Southwest University of Science and Technology,
Mianyang Sichuan 621010, China)

Abstract: In view of the disadvantages of current methods for load forecasting in power system, a new algorithm named fuzzy support vector kernel regression method (F-SVKR) is proposed to deal with the problem. Comparison with some conventional methods, such as the artificial neural network, Kalman filtering algorithm, the method of minimizing absolute parameter estimation, the support vector machine and so on, have been performed. Experimental results show their performance differences and provide some reference information for the further research in this domain.

Key words: power system; load forecasting; fuzzy logic; support vector machine; kernel function

1 引言(Introduction)

负荷预测是电力系统一项基本工作, 直接影响到整个电力系统运行的经济效益。研究表明^[1]: 在挪威, 短期负荷预测的误差每增加1%, 整个电力系统的年运行成本将增加450~910万元; 在英国这个值是1770万元; 在我国, 受现实因素制约, 增加的成本大约是英国的6~8倍。因此根据历史负荷数据和相关条件预测电网负荷是一个值得深入研究的课题。许多学者做了大量的研究: 胡政^[2]介绍的高峰负荷决策平台可以为调度人员提供有效的决策支持信息; 李端超^[3]利用超短期负荷预测的结果, 使发电机组能较准确地响应负荷变化。

主要方法有: 时序分析^[4]、最小二乘^[5]、灰色理论^[6]、神经网络^[7,8]、Kalman滤波^[9]、最小绝对值参数估计^[10]、概率法^[11]、置信区间法^[12]、支持向量机^[13,14]等。它们各有优势, 但也有一些不足: 卡尔

曼滤波容易剔除有用数据; 概率法和置信区间法主观性较强; 最小绝对值参数法依赖先验知识, 数据集变化时, 参数的重调比较花费时间; 神经网络的本质是通过梯度下降法进行寻优, 容易出现局部极值和过学习现象; 部分学者采用支持向量机来处理负荷数据, 并引入遗传算法、模糊逻辑和小波技术来提高性能, 效果较好, 但处理环节的增加将降低收敛速度, 小波的引入使学习机对噪声敏感。

本文在李昆仑^[15]等及本人研究成果的基础上进一步完善了基于模糊支持向量的核回归方法, 首先将非线性回归问题转化为有限维非线性模糊分类问题, 获得广义模糊最优分类超平面, 把不等式约束下的二次规划转化为机会约束规划^[16](fuzzy chance constrained programming, FCCP), 以此为基础构建核回归机, 并采用实验的方式对几种典型方法的性能做出了对比。

2 模糊支持向量核回归方法(Fuzzy support vector kernel regression method)

2.1 核函数方法(Kernel function method)

Minsky明确指出线性学习机器的计算能力有限^[17], 目标概念通常不能由给定属性的简单线性组合产生, 而是需要从更本质的层次提取更抽象的特征. 核函数方法为此提供了有效的解决途径, 它通过一个非线性变换 Φ 将原始空间映射到一个新的特征空间, 即

$$\begin{aligned} x &= (x_1, x_2, \dots, x_n) \xrightarrow{\Phi} \Phi(x), \\ \Phi(x) &= (\Phi(x_1), \Phi(x_2), \dots, \Phi(x_n)). \end{aligned} \quad (1)$$

核函数为支持向量机(support vector machine, SVM)提供了重要的模块, 构造回归估计函数

$$f(x) = \langle w \cdot \Phi(x) \rangle + b. \quad (2)$$

优化目标是

$$\begin{cases} \min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s.t. } |y_i - \langle w \cdot \Phi(x_i) \rangle - b| \leq \varepsilon + \xi_i, \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n. \end{cases} \quad (3)$$

松弛变量 ξ_i, ξ_i^* 和惩罚系数 $C > 0$ 用于对超出 ε 管道的样本点进行调节. 引入Lagrange乘子把它转化成无约束二次规划

$$\max_{\alpha, \alpha^*, \beta, \beta^*} \left[\min_{w, b, \xi} [L(w, b, \xi, \xi^*)] \right]. \quad (4)$$

其中:

$$\begin{aligned} L(w, b, \xi, \xi^*) &= \\ &\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - \\ &(y_i - \langle w \cdot \Phi(x_i) \rangle - b)) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + \\ &(y_i - \langle w \cdot \Phi(x_i) \rangle - b)) - \sum_{i=1}^n (\beta_i \xi_i + \beta_i^* \xi_i^*), \end{aligned}$$

$\alpha, \alpha^*, \beta, \beta^*$ 是Lagrange乘子. 用 L 分别对 w, b, ξ, ξ^* 求偏导并令其为零, 将结果代入式(4)得

$$\begin{cases} \max_{\alpha, \alpha^*, \beta, \beta^*} -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [(\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_j, x_j)] - \\ \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*), \\ \text{s.t. } \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, 0 \leq \alpha_i \leq C, 0 \leq \alpha_i^* \leq C. \end{cases}$$

根据KKT条件^[17]有

$$\begin{cases} \alpha_i [\varepsilon + \xi_i - (y_i - \langle w \cdot \Phi(x_i) \rangle - b)] = 0, \\ \alpha_i^* [\varepsilon + \xi_i^* - (y_i - \langle w \cdot \Phi(x_i) \rangle - b)] = 0. \end{cases} \quad (5)$$

$\alpha \neq 0$ 对应的样本称作支持向量, 对支持向量 x_i, ξ, ξ^* 为零, 求得

$$b = y_i - \sum_{j=1}^n (\alpha_j - \alpha_j^*)K(x_j, x_j) - \varepsilon. \quad (6)$$

把 w 和 b 代入式(2), 得到回归估计函数

$$f(x) = \sum_{x \in SV} (\alpha_i - \alpha_i^*)K(x_i, x) + b. \quad (7)$$

2.2 模糊支持向量核回归方法(Fuzzy support vector kernel regression method)

针对负荷的模糊、非线性特点, 在已有成果的基础上进一步完善了模糊支持向量核方法(fuzzy support vector kernel regression, F-SVKR). 给定样本集 $S = \{(x_i, y_i), i = 1, 2, \dots, n\}$, 输出模糊时传统的核函数方法将不能求解, 因为无法求解对应的最优分类超平面. 本文采取以下策略: 首先把回归问题转化成有限维模糊分类问题, 得到模糊样本集

$$\begin{cases} S_F = \{(x_i, y_i \pm \delta_{y_i}, s_i); z_j\}, \\ \text{s.t. } i = 1, 2, \dots, n, j = 1, 2, \dots, m, m \leq n. \end{cases} \quad (8)$$

其中: $(x_i, y_i \pm \delta_{y_i})$ 作为输入, s_i 是对应的模糊隶属函数, $z_j = \pm 1$ 是第 j 类的输出. 将原空间 L 映射到特征空间 H , 核函数为 K , 令第 k 类样本中心为 \bar{x}_k , 该类中 x_{kt} 的广义模糊隶属距离为

$$d_k(t) = \sqrt{K(\bar{x}, \bar{x}) + K(\bar{x}, x_{kt}) + K(x_{kt}, x_{kt})}. \quad (9)$$

定义样本点 x_{kt} 的模糊隶属函数为

$$s_k(t) = d_k(t) / \max(d_k). \quad (10)$$

令 $y_f = y \pm \delta_y$, 它将导致权向量 w 和阈值 b 的模糊, 由此构建广义模糊最优分类超平面:

$$\langle w_F \cdot \Phi(x) \rangle + sy_F + b_F = 0. \quad (11)$$

非线性不可分情况下, 引入松弛变量 ξ 得

$$\begin{cases} [z_j (\langle w_F \cdot \Phi(x) \rangle + sy_F + b) - 1] + \xi_j \geq 0, \\ \text{s.t. } j = 1, 2, \dots, m. \end{cases} \quad (12)$$

原二次规划转化成模糊决策机会约束规划

$$\begin{cases} \min \left\{ \Phi(w, s, C, \xi) = \left[\frac{1}{2} (\|w_F\|^2 + s^2 + C \sum_{j=1}^m \xi_j) \right] \right\} \\ \text{s.t. } P \left[\frac{1}{2} \left(\|w_F\|^2 + s^2 + C \sum_{j=1}^m \xi_j \right) \leq \eta \right] \geq \tau_1, \\ P \{ 1 - z[\langle w_F \cdot \Phi(x) \rangle + sy_F + b_F] \geq \gamma \} \leq \tau_2. \end{cases}$$

$C = f[d(j)]$ 是惩罚因子, 定义为广义模糊隶属距离 d 的函数, f 为线性函数 $C = c \cdot d(j)$; $\xi \geq 0$ 是松弛变量; $\tau_1 \geq 0, \tau_2 \geq 0$ 是置信水平; $\eta \geq 0, \gamma \geq 0$ 是阈值; $P\{\}$ 表征事件的概率测度.

引入Lagrange乘子 α, β 得

$$\begin{aligned} \min[L(w, b, \xi)] = \\ \min\left\{\frac{1}{2}\|w_F\|^2 + C \sum_{i=1}^n s_i \xi_i - \sum_{i=1}^n \alpha_i \xi_i - \sum_{i=1}^n \beta_i \{\varepsilon + \xi_i + 1 - z_i [\langle w_F \cdot \Phi(x_i) \rangle + s(i)y_F(i) + b_F(i)]\}\right\}. \end{aligned} \quad (13)$$

用Lagrange乘子对 w, b, ξ 求偏导, 将结果代入式(13), 得

$$\begin{aligned} \min\left\{\frac{1}{2} \sum_{i,j=1}^n \left(\sum_{h=1}^k z_{ih} \alpha_{ih} - \alpha_{ih} \right) \cdot \left(\sum_{h=1}^k z_{jh} \alpha_{jh} - \alpha_{jh} \right) \langle \varphi(x_i) \cdot \varphi(x_j) \rangle - \sum_{i,j=1}^k [z_j \left(\sum_{h=1}^k (\alpha_{ih} - \alpha_{jh}) \langle \varphi(x_i) \cdot \varphi(x_j) \rangle \right) + b_F - 2] - \sum_{i=1}^n \sum_{h=1}^k [(\alpha_{ih} - C s_{ih} + \beta_{ih}) \xi_{ih}]\right\}. \end{aligned}$$

约束条件为 $\sum_{svm} \alpha_{svm} = \sum_{i=1}^n \sum_{h=1}^k z_{ih} \alpha_{ih}$, 可得决策函数

$$\begin{aligned} f(x) = \\ \arg \max \left[\sum_{svm} \left(\sum_{h=1}^k z_h \alpha_h - \alpha_{svm} \right) \cdot K(x, x_i) + b \right]. \end{aligned}$$

其中 K 为核函数, 取该类中心为预测值.

3 短期峰值负荷预测实例(Experiments of short-term peak load forecasting)

3.1 数据预处理(Data pre-treatment)

实验数据是广安市供电局一条10kV输电线路2003年12月1日~2004年12月31日的历史数据. 负荷受多种因素影响, 比如节假日 F 、日平均气温 T 、日最高气温 T_H 及持续时间 t_H 、日最低气温 T_L 及持续时间 t_L 、空气湿度 H 、居民生活水平 L 、电能在能源消耗中的比重 P 等. 由于做的是短期峰值预测, 只取 F, T, T_H, T_L (考虑量纲不同, 做了量化处理).

取预测日前28天的数据, 按是否节假日分成两种数据类型. 2004年全年366天, 形成366个可用数据集. 每个非节假日数据集包含22~24个数据, 每个节假日数据集包含4~6个数据, 这些数据是预测日前28天的温度测量值和每天的最大负荷测量值, 以列向量的方式排列形成 $m \times n$ 矩阵.

对这种时间序列, 越接近预测日的数据对预测准确度的影响越大, 设置权重

$$W(P) = \frac{a}{(b+1)^P}, \quad (14)$$

a, b 是可调参数, P 是与预测日相隔的天数.

3.2 对比实验采用的算法(Algorithms used in comparison experiment)

对比实验采用的算法有

- ① 模糊支持向量核回归方法F-SVKR;
- ② 神经网络^[7,8], 简记为ANN;
- ③ 卡尔曼滤波^[9], 简记为KF;
- ④ 最小绝对值参数估计法^[10], 简记为LAPE;
- ⑤ 结合遗传算法的支持向量机^[13], 简记为GSVM;

⑥ 结合模糊小波技术的支持向量机^[14], 简记为FWSVM.

在MATLAB 6.5环境下, 根据以上参考文献介绍的算法原理进行编程.

3.3 F-SVKR参数选择与分析(Parameters selection and analysis of F-SVKR)

实验中, F-SVKR选择高斯核作核函数, 即

$$K(x, x_i) = \exp(-|x - x_i|^2 / \sigma^2). \quad (15)$$

核参数 σ 、惩罚因子 $C = c \cdot d(j)$ 的参数 c , ξ 管道半径对预测精度的影响很大, 应仔细优化. 取核参数 $\sigma = 4.2, c = 71.5, \varepsilon = 0.0012$. 定义误差指标为相对偏差百分比, 即

$$Err = [|L_F - L_R| / L_R] \cdot 100\%. \quad (16)$$

其中: L_F 为预测值, L_R 为负荷的测量值.

固定 c, ε, σ 在 $[0.1, 15]$ 之间变化, 步长0.1, Err 先减小后增大, 在4.2附近形成谷点.

固定 σ, ε, c 在 $[1, 150]$ 之间变化, 步长0.5, Err 先减小后增大, 在71.5附近形成谷点.

固定 σ, c, ε 在 $[0.0001, 1]$ 之间变化, 步长0.0001, Err 在0.0012附近形成谷点.

式(14)的权重参数为 $a = 82, b = 237$.

3.4 实验结果(Experiment results)

取366个数据集中第2,5,8,11月数据为测试集, 其余8个月作为样本集进行训练, 获得4个峰值负荷预测结果. 限于篇幅, 这里只列出11月的预测情况, 如表1所示.

均值误差和均方根误差按下式计算:

$$E_{mape} = \frac{1}{N} \sum_{i=1}^N \left| \frac{L_R(i) - L_F(i)}{L_R(i)} \right| \times 100\%, \quad (17)$$

$$E_{mse} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{L_R(i) - L_F(i)}{L_R(i)} \right)^2} \times 100\%. \quad (18)$$

其中 N 是当月天数.

F-SVKR的精度与GSVM和FWSVM相近, 优于另几种方法.

表1 第11月的预测结果

Table 1		Forecasting values of November				MW
测量值	ANN	KF	LAPE	GSVM	FWSVM	F-SVFR
57.5075	60.6937	62.5145	62.5145	58.6232	58.0484	57.4737
54.0786	52.4078	55.0281	53.9800	56.9232	56.3651	55.8070
61.8717	56.3881	59.2075	58.6437	61.5277	60.9303	59.7356
60.9795	60.6942	57.6595	57.6595	57.0242	57.0242	58.1880
61.6783	63.2561	66.4189	65.7863	58.8909	58.8909	60.0927
60.9741	54.3888	56.0205	56.0205	60.5660	59.9722	59.3785
54.2332	53.0607	50.4076	50.4076	54.6909	54.6909	55.8070
54.0100	53.2899	55.9544	55.4215	55.8576	55.8576	56.9975
52.4895	58.6867	61.6210	55.7524	54.1076	54.1076	55.2118
56.5664	55.2158	56.8723	56.8723	59.3517	58.7699	58.1880
58.1571	56.1353	57.8193	57.8193	56.4375	55.8842	55.3308
57.7516	54.8221	56.4667	56.4667	56.9232	56.3651	55.8070
60.8015	62.0908	63.9535	63.9535	59.8375	59.2508	58.6642
58.6399	58.3871	55.4678	55.4678	58.7742	58.7742	59.9737
53.9593	51.5272	54.1036	53.0730	55.5875	55.0425	54.4975
57.2975	50.0462	52.5485	52.0480	56.9908	56.4375	55.3308
56.7489	60.2413	57.2292	62.0485	55.1311	55.1311	55.6880
57.3857	60.1192	63.1252	62.5240	61.2824	60.6875	59.4975
56.6324	54.7916	52.0520	52.0520	58.3076	58.3076	59.4975
58.7715	63.2019	65.0979	65.0979	59.5946	57.8418	58.4261
60.8090	59.5192	62.4951	61.8999	58.0742	58.0742	59.2594
51.8637	59.7080	61.4993	61.4993	55.7089	55.1627	54.6166
53.4240	57.7923	54.9027	59.5260	54.7775	54.7775	55.3308
57.9828	58.1571	55.2493	55.2493	56.6742	56.6742	57.8308
56.5205	51.6018	54.1819	53.6659	53.8742	53.8742	54.9737
60.8279	58.3360	60.0861	60.0861	59.4732	58.8901	58.3070
54.5019	54.7566	56.3993	56.3993	56.1946	55.6437	55.0927
62.0216	57.6234	54.7422	54.7422	58.5409	58.5409	59.7356
54.9895	56.3227	59.1388	58.0124	58.5017	57.9282	57.3547
54.8414	60.2362	57.2244	60.8385	57.0168	57.0168	57.5927
E_{mape}	5.40%	6.24%	6.35%	3.27%	3.23%	3.21%
E_{mse}	6.62%	7.63%	7.48%	3.83%	3.62%	3.51%

4 结论(Conclusions)

本文分析了电网负荷的特点,在已有成果的基础上进一步完善了F-SVKR方法.与神经网络、卡尔曼滤波、最小绝对值参数估计、GSVM和FWSVM等几种算法进行对比实验,实验结果表明F-SVKR与GSVM和FWSVM性能相近,优于另外几种方法,同时表明对这类模糊、非线性和强扰动的系统,支持向量方法性能相对稳定.

相对来说,F-SVKR的处理速度要快得多,由于每台电脑的软硬件配置不同,所花时间具有个体差异,不能作为精确的标准来衡量算法的优劣,本

文考虑在同一台电脑上实验,用时间的相对值来比较算法的性能:F-SVKR花费的时间定义为 T ;在GSVM中由于遗传算法的引入,花费的时间大约为 $3.8T$;FWSVM的精度与F-SVKR接近,但它引入了模糊逻辑和小波技术两个环节,处理时间大约为 $2.17T$,小波的引入使学习机器对噪声特别敏感.

在实验中笔者体会到,F-SVKR虽然表现出较好的性能,但也存在一些不足.进一步探讨支持向量的预提取方法以便减小该方法的后期计算复杂度,是下一步要做的工作;深入分析负荷特点,构建性能更好的回归机也有待进一步探讨.

参考文献(References):

- [1] LIU K. Comparison of very short-term load forecasting technique[J]. *IEEE Trans on Power Systems*, 1996, 11(2): 877 – 882.
- [2] 胡政, 柳进, 胡林献. 电网高峰负荷分析决策平台的设计与实现[J]. 电网技术, 2005, 29(6): 58 – 62.
(HU Zheng, LIU Jin, HU Linxian. Design and implementation of power system peak load analysis and decision-making platform[J]. *Power System Technology*, 2005, 29(6): 58 – 62.)
- [3] 李端超, 谢恒, 江山立, 等. 安徽电网实时发电控制系统设计及实现[J]. 电网技术, 2001, 25(1): 62 – 66.
(LI Duanchao, XIE Heng, JIANG Shanli, et al. Design and implementation of real-time generation control system for ANHUI power system[J]. *Power System Technology*, 2001, 25(1): 62 – 66.)
- [4] FRANKLIN P W. A theoretical study of the three phase salient pole type generator with simultaneous AC and bridge rectified DC output, part I and part II[J]. *IEEE Trans on Power Apparatus and Systems*, 1973, 92(2): 543 – 557.
- [5] SCHIFERL R F. Six phase synchronous machine with AC and DC stator connections, part I and part II[J]. *IEEE Trans on Power Apparatus and Systems*, 1983, 102(8): 2685 – 2701.
- [6] MA Weiming, ZHANG Gaifan, LIU Dezhi, et al. A synchronous machine with simultaneous AD/DC output: the Patent of China, ZL 94107628.8[P]. 1999, 09, 11. Wuhan, Hubei: Navy Engineering Institute of PLA, 1999..
- [7] 尤勇, 盛万兴, 王孙安. 基于人工免疫网络的短期负荷预测模型[J]. 中国电机工程学报, 2003, 23(3): 26 – 30.
(YOU Yong, SHENG Wanxing, WANG Sun'an. Short-term load forecasting using artificial immune network[J]. *Proceedings of the CSEE*, 2003, 23(3): 26 – 30.)
- [8] 谢宏, 程浩忠, 张国立, 等. 基于粗糙集理论建立短期电力负荷神经网络预测模型[J]. 中国电机工程学报, 2003, 23(11): 1 – 4.
(XIE Hong, CHENG Haozhong, ZHANG Guoli, et al. Applying rough set theory to establish artificial neural networks for short term load forecasting [J]. *Proceedings of the CSEE*, 2003, 23(11): 1 – 4.)
- [9] AL-HAMADI H M, SOLIMAN S A. Short-term electric load forecasting based on kalman filtering algorithm with moving window weather and load model[J]. *Electric Power Systems Research*, 2004, 68(1): 47 – 59.
- [10] SOLIMAN S A, PERSAUD S, EI-NAGAR K, et al. Application of least absolute value parameter estimation based on linear programming to short-term load forecasting[J]. *Electrical Power and Energy Systems*, 1997, 19(3): 209 – 216.
- [11] HOFFER J, PRILL M. On the models of peak load forecast uncertainty in probabilistic production costing algorithms[J]. *Electrical Power and Energy Systems*, 1996, 18(3): 153 – 160.
- [12] CHARYTONIUK W, NIEBRZYDOWSKI J. Confidence interval construction for load forecast[J]. *Electric Power Systems Research*, 1998, 48(2): 97 – 103.
- [13] PAI P F, HONG W C. Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms[J]. *Electric Power Systems Research*, 2005, 74: 417 – 425.
- [14] LI Yuancheng, LI Bo, FANG Tingjian. Short-term load forecast based on fuzzy wavelet support vector machines[C]// *Proc of the Fifth World Congress on Intelligent Control and Automation*. Hangzhou: WCICA'2004, 2004, 6: 5194 – 5201.
- [15] 李昆仑, 黄厚宽, 田盛丰. 模糊多类SVM模型[J]. 电子学报, 2004, 32(5): 830 – 832.
(LI Kunlun, HUANG Houkuan, TIAN Shengfeng. Fuzzy support vector machine for multi-class classification[J]. *Acta Electronic Sinica*, 2004, 32(5): 830 – 832.)
- [16] 赵晓煜, 汪定伟. 供应链中二级分销网络优化设计的模糊机会约束规划模型[J]. 控制理论与应用, 2002, 19(2): 249 – 253.
(ZHAO Xiaoyu, WANG Dingwei. Fuzzy chance constrained programming model for bio-level distribution network design in the supply chain [J]. *Control Theory & Applications*, 2002, 19(2): 249 – 253.)
- [17] VAPNIK V N. *Statistical Learning Theory*[M]. New York: Springer-Verlag, 2000: 87 – 150.

作者简介:

蒋刚 (1978—), 男, 博士, 副研究员, 目前研究方向为信号处理、人工智能等, E-mail: jgg0429@tom.com.