

基于特征选择和iJaya-SVR的年度电力消费预测研究

高峰, 邵雪焱

引用本文:

高峰, 邵雪焱. 基于特征选择和iJaya-SVR的年度电力消费预测研究[J]. *控制与决策*, 2024, 39(3): 1039–1047.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1488>

您可能感兴趣的其他文章

Articles you may be interested in

[基于卷积长短时记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

[基于MI-SVR模型的航空旅客出行指数预测方法研究](#)

Air passenger index prediction method based on MI-SVR mode

控制与决策. 2021, 36(7): 1619–1626 <https://doi.org/10.13195/j.kzyjc.2019.1446>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于Fisher Score与最大信息系数的齿轮箱故障特征选择方法](#)

Fault feature selection method of gearbox based on Fisher Score and maximum information coefficient

控制与决策. 2021, 36(9): 2234–2240 <https://doi.org/10.13195/j.kzyjc.2019.1770>

基于特征选择和iJaya-SVR的年度电力消费预测研究

高峰^{1,2}, 邵雪焱^{2†}

(1. 北京大学工学院, 北京 100871; 2. 中国科学院科技战略咨询研究院, 北京 100190)

摘要: 准确的电力消费预测对能源规划和政策制定具有重要意义. 鉴于已有研究忽略了特征冗余以及智能优化算法控制参数不确定对预测精度的影响, 引入最大相关最小冗余(MRMR)算法筛选电力消费的关键影响因素作为预测指标, 提出改进的Jaya算法(iJaya)用于优化支持向量回归(SVR)的超参数, 进而构建MRMR-iJaya-SVR预测模型. 以我国的年度电力消费数据为例, 对MRMR-iJaya-SVR模型的预测效果进行验证, 并利用北京市的年度电力消费数据测试其鲁棒性. 结果表明: iJaya算法具有较强的全局搜索能力和较好的稳定性, MRMR-iJaya-SVR模型在单步预测和多步预测中的表现均优于基准模型. 此外, 对于不同的数据集, MRMR-iJaya-SVR模型均具有良好的鲁棒性.

关键词: 特征选择; 改进的Jaya算法; 最大相关最小冗余; 支持向量回归; 混合预测模型; 电力消费预测

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1488

引用格式: 高峰, 邵雪焱. 基于特征选择和iJaya-SVR的年度电力消费预测研究[J]. 控制与决策, 2024, 39(3): 1039-1047.

Prediction of annual electricity consumption based on feature selection and iJaya-SVR

GAO Feng^{1,2}, SHAO Xue-yan^{2†}

(1. College of Engineering, Peking University, Beijing 100871, China; 2. Institutes of Science and Development, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: Accurate forecasting of annual electricity consumption is of great significance for energy planning and policy making. Given that the literature ignores the impact of feature redundancy and uncertainty of algorithm-specific control parameters of an intelligent optimization algorithm on forecasting accuracy, this paper introduces a max-relevance and min-redundancy (MRMR) algorithm to select the key influencing factors as predictors, proposes an improved Jaya algorithm (iJaya) to optimize the hyper-parameters of support vector regression (SVR) and constructs the annual electricity consumption forecasting model MRMR-iJaya-SVR. Taking the real electricity consumption data of China as an example, this paper validates the forecasting performance of the MRMR-iJaya-SVR. Besides, the yearly electricity consumption data of Beijing are used to test the robustness of the proposed model. The experimental results show that the iJaya algorithm has better global searching ability and is more stable. And the proposed model outperforms benchmark models in both single-step-ahead and multi-step-ahead forecasting. Furthermore, for different datasets, the proposed model has strong robustness.

Keywords: feature selection; iJaya; max-relevance and min-redundancy; support vector regression; hybrid forecasting model; electricity consumption forecasting

0 引言

随着经济的快速发展和人口数量的持续增加, 我国电力消费规模不断创出新高. 据统计, 自2010年以来, 我国电力消费已经增长了近2倍, 年均增速约为7.8%. 2020年9月, 习近平主席在第75届联合国大会一般性辩论上提出, 我国力争于2030年前实现碳达峰,

2060年前实现碳中和. 为了实现上述目标, 我国从中央到地方进行了一系列决策部署, 如大力发展可再生能源、提升终端电气化水平等, 这些措施将进一步推动我国电力需求的增长. 根据国际能源署发布的《2050年净零排放》报告, 在碳中和情景下, 中国电力需求将保持持续快速增长的趋势^[1]. 在此背景下,

收稿日期: 2022-08-20; 录用日期: 2023-01-20.

责任编辑: 樊治平.

†通讯作者. E-mail: xyshao@casisd.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

准确的电力消费预测不仅有助于政府制定政策保证供电安全,也可为电力基础设施建设的长期规划提供参考.然而,年度电力消费具有样本量小、影响因素众多以及影响因素之间关系复杂等特点,这些特点使得年度电力消费预测十分困难.因此,如何提升年度电力消费预测精度是一个重要的研究问题.

目前,已有众多学者对年度电力消费预测模型进行了研究,这些模型大致可分为两大类:计量经济模型和机器学习模型.用于电力消费预测的计量经济模型主要包括整合移动平均自回归模型(ARIMA)^[2]、指数平滑^[3]、线性回归模型^[4-6]等.上述模型虽然计算简单,但均基于线性假设,难以捕捉电力消费与影响因素之间的非线性关系,预测精度较低.随着计算机技术的快速发展,机器学习模型逐渐被用于年度电力消费预测.相对于计量经济模型,机器学习模型在拟合非线性关系方面具有明显的优势.在年度电力消费预测中,常用的机器学习模型包括神经网络(ANN)^[7-9]和支持向量回归(SVR)^[10-11].ANN模型虽然具有较好的非线性拟合能力,但需要大量数据来训练参数.受年度电力消费样本较少的制约,运用ANN建模进行预测时容易出现过拟合现象.SVR以统计学理论为基础,对小样本具有良好的泛化能力^[12].如Hong^[11]利用SVR对年度电力消费进行预测,实证结果表明SVR比ANN的预测性能更好.但是,SVR的预测精度在很大程度上依赖于超参数的选择.为了解决这个问题,部分学者将智能优化算法用于优化SVR的超参数.如Wang等^[13]和Pai等^[14]分别利用差分进化算法(DE)和遗传算法(GA)优化SVR超参数,构建了年度电力消费的混合预测模型,研究结果表明经过优化后的SVR具有更高的预测精度.然而,上述智能优化算法均包含较多的需要人为设定的控制参数,如GA的交叉概率、变异概率,增加了模型的不确定性.

除了模型选择,影响因素(特征)的选取也是年度电力消费预测的关键问题.目前,年度电力消费预测主要选取经济增长、人口数量等宏观社会经济变量作为输入变量.例如,董景荣^[15]选取国内生产总值、电力消费价格指数和社会人口总数作为影响因素,建立年度电力消费预测模型.李菁等^[16]基于产业结构、能源效率改进、社会消费总额、人口、地区生产总值和电力价格指数预测武汉市年度电力消费.张运厚等^[17]选取GDP、人均GDP、工业增加值和上一年度用电量作为输入变量预测北京市的年度电力消费量.何晓萍等^[18]分析了GDP、城市化、工业化、电

力使用效率和电价水平与电力消费量之间的关系,并对中国未来的人均电力需求进行了预测.尽管选取的这些变量均是年度电力消费的影响因素,但部分变量之间具有高度相关关系,即存在特征冗余现象,会降低预测模型的精度^[19-20].

综上,已有文献对年度电力消费预测做了大量工作,但仍然存在一定的不足.总结起来,主要有以下两个方面:一是,已有研究在构建预测模型时多以个人经验或者文献总结等方式选取年度电力消费的影响因素,较少考虑特征冗余对预测精度的影响;二是,已有研究在对SVR的超参数进行优化时,存在优化算法控制参数难以确定的问题.为此,本文引入最大相关最小冗余(MRMR)算法对年度电力消费的关键影响因素进行筛选,以消除冗余的特征,提出一种改进的Jaya算法(iJaya)用于优化SVR的超参数.iJaya算法无自身特定的控制参数,可有效解决控制参数难以确定的问题.以我国的年度电力消费数据为例进行实证分析,验证所提模型(MRMR-iJaya-SVR)的预测效果,并利用北京市的年度电力消费数据测试其鲁棒性.

1 方法原理概述

1.1 最大相关最小冗余算法

MRMR算法是一种有效的过滤型特征选择方法,其显著的特点是可同时实现最大化自变量与因变量的相关性和最小化自变量之间的相关性^[21].该算法采用互信息来度量变量之间的相关性,相对于皮尔森相关系数而言,互信息可以度量非线性相关关系^[22-23],具有更为广泛的应用范围.具体而言,互信息是一种度量两个随机变量之间相关程度的方法,从数学上可以理解为一个随机变量 x 对另外一个随机变量 y 的不确定性的减少程度.假设已知这两个随机变量的联合概率密度函数 $p(x, y)$ 和边缘概率密度函数 $p(x)$ 、 $p(y)$,互信息可以表示为

$$I(x, y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy. \quad (1)$$

MRMR算法包含最大相关和最小冗余两部分.最大相关是指挑选出的特征与目标变量的互信息均值最大.假设 S 为挑选出的最优特征子集, $|S|$ 为特征子集 S 中的特征数量,则最大相关的表达式如下所示:

$$\max D(S, y), D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; y). \quad (2)$$

根据最大相关准则筛选出的特征之间可能存在多重共线性(冗余)等问题,从而影响预测精度.因此,

为了减少冗余特征,在最大相关的基础上引入最小冗余的约束,即挑选出的特征之间的互信息均值最小,表达式如下:

$$\min R(S), R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i; x_j). \quad (3)$$

将两个约束相结合就构成了最大相关最小冗余,定义算子 $\psi(D, R)$,最大化该算子即可同时优化 D 和 R ,可表示为

$$\max \psi(D, R), \psi = D - R. \quad (4)$$

为了便于求解,可采用增量搜索的方法来搜寻所需特征.假设全部特征的集合为 X ,已选出特征的集合为 S_{m-1} ,其中有 $m-1$ 个特征,搜索的目标是从剩余特征集合 $X - S_{m-1}$ 选择第 m 个特征,且需要满足式(4)的要求,具体表达式如下:

$$\max_{x_j \in X - S_{m-1}} \left[I(x_j; y) - \frac{1}{m-1} \sum_{x_i \in S_{m-1}} I(x_j; x_i) \right]. \quad (5)$$

MRMR算法的具体流程可以表示如下:

step 1: 从特征集 X 中选择与目标变量之间互信息最大的特征 x_j 放入最优特征子集 S ;

step 2: 利用增量搜索的方法选择满足条件的 x_j 放入最优特征子集 S ;

step 3: 判定是否达到设定的阈值(通常设置 $\psi(D, R) > 0$),如果满足阈值条件则输出选择的特征,否则执行step 2.

1.2 支持向量回归

支持向量回归(SVR)是Vapnik^[24]提出的一种基于结构风险最小化的机器学习算法,对小样本、非线性数据具有较好的拟合能力^[25-26],其核心思想是寻找一个超平面,使得所有训练样本数据到该平面的距离最小.设样本训练集为 $(\mathbf{x}_i, y_i), i = 1, 2, \dots, n, \mathbf{x} \in R^m, y \in R$,回归函数可表示为

$$f(x) = (\boldsymbol{\omega} \cdot \mathbf{x}) + b, \boldsymbol{\omega} \in R^m, b \in R. \quad (6)$$

其中: $\boldsymbol{\omega}$ 表示权重向量, b 表示偏置量, R^m 和 R 分别表示 m 维向量空间和一维向量空间. $\boldsymbol{\omega}$ 和 b 通过结构风险最小化进行估计,表达式如下:

$$\min R(f) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{C}{2} \sum_{i=1}^n L(y_i, f(\mathbf{x}_i)). \quad (7)$$

其中: L 为损失函数, C 为惩罚因子.

引入松弛变量 ξ_i 和 ξ_i^* ,式(7)可转化为凸二次优化问题

$$\min \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*); \quad (8)$$

$$y_i - \boldsymbol{\omega} \cdot \mathbf{x}_i - b \leq \epsilon + \xi_i, \quad (9)$$

$$\boldsymbol{\omega} \cdot \mathbf{x}_i + b - y_i \leq \epsilon + \xi_i^*, \quad (10)$$

$$\xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, n. \quad (11)$$

为了便于求解,将该问题转化为对偶问题

$$\max -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)(\mathbf{x}_i \cdot \mathbf{x}_j) - \epsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*); \quad (12)$$

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, \alpha_i, \alpha_i^* \in [0, C]. \quad (13)$$

则回归函数可表示为

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*)(\mathbf{x}_i \cdot \mathbf{x}) + b. \quad (14)$$

引入核函数,上式可变为

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*)K(\mathbf{x}_i, \mathbf{x}) + b, \quad (15)$$

其中 $K(\mathbf{x}_i, \mathbf{x})$ 为核函数.

常用的核函数有线性核函数 $K(\mathbf{x}_i, \mathbf{x}) = \mathbf{x}_i^T \mathbf{x}$,多项式函数 $K(\mathbf{x}_i, \mathbf{x}) = (\mathbf{x}_i \cdot \mathbf{x} + c)^d$,径向基(高斯)核函数 $K(\mathbf{x}_i, \mathbf{x}) = e^{-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2}$ 等.其中,径向基核函数又名高斯核函数,对复杂的非线性关系具有较好的映射能力^[27],因此本文采用径向基核函数.对于径向基SVR而言,超参数主要包括惩罚因子 C 和核参数 γ .

1.3 Jaya算法

Jaya算法是Venkata^[28]提出的一种新型的群智能优化算法,该算法可用于解决无约束和带约束的优化问题.与传统的智能优化算法相比,Jaya算法最显著的特点是参数少,只有种群数量和最大迭代次数这两个群智能算法共有的参数.其他多数智能优化算法还需要自身特有的控制参数,例如遗传算法的交叉概率和变异概率等特定控制参数.智能优化算法的参数,尤其是控制参数,具有较高不确定性,其取值对优化结果影响较大.因此,在使用控制参数较多的优化算法时,如何设定合适的控制参数值一直困扰着诸多学者,而Jaya算法可以较为有效地避免这个问题.Jaya算法的主要思想是在迭代过程中通过不断靠近最优个体(解)同时远离最差个体(解)的方式搜寻全局最优解,具体表达式如下:

$$X'_{j,k,i} = X_{j,k,i} + \text{rbest}_{j,i}(X_{j,\text{best},i} - |X_{j,k,i}|) - \text{rworst}_{j,i}(X_{j,\text{worst},i} - |X_{j,k,i}|). \quad (16)$$

其中: $X_{j,k,i}$ 表示在第 i 次迭代中个体 k 的第 j 个变量值, $X'_{j,k,i}$ 表示 $X_{j,k,i}$ 更新后的值, $\text{rbest}_{j,i}$ 和 $\text{rworst}_{j,i}$ 表示两个取值范围为 $[0, 1]$ 的随机变量, $X_{j,\text{best},i}$ 表示第 i 次迭代中最优个体的第 j 个变量值, $X_{j,\text{worst},i}$ 表示第 i 次迭代中最差个体的第 j 个变量值.

2 MRMR-iJaya-SVR混合模型

2.1 iJaya算法

经典Jaya算法也存在一定的不足,首先,在个体更新时,每个变量乘以不同的随机数将导致个体的移动方向具有随机性,无法直接朝着最优个体的方向移动,这种更新方式导致算法收敛速度较慢;其次,在当前迭代中的最优个体为历史全局最优解,其他所有个体在下次迭代中均向着该个体所在位置移动,这在一定程度上限制了种群的全局探索能力,导致陷入局部最优.针对以上问题,本文在已有研究基础上,对经典Jaya算法进行改进,提出iJaya算法. iJaya算法通过改变个体的更新方式来提升收敛速度,通过增加探索阶段来提高全局搜索能力,具体如下.

1) 改变个体变量更新方式. 若个体的所有变量均乘以同一个随机数,个体将直接朝着最优个体的方向移动,收敛速度会更快.因此,本文将个体更新方式改为所有变量均乘以同一个随机数,表达式如下:

$$X'_{k,i} = X_{k,i} + \text{rbest}_i(X_{\text{best},i} - |X_{k,i}|) - \text{rworst}_i(X_{\text{worst},i} - |X_{k,i}|). \quad (17)$$

2) 增加全局探索机制. 本文将iJaya算法的迭代过程划分为两个阶段:探索阶段和开发阶段.在探索阶段,每个个体朝着上次迭代中的最优个体移动,同时远离最差个体,但不与历史迭代中的全局最优个体进行比较,任由每个个体进行自由探索,并记录探索中找到的最优位置.在开发阶段,保留经典Jaya算法的个体移动方式,且第一次迭代中的最优个体位置为探索阶段中找到的最优个体位置.

为了验证iJaya算法的搜索性能,本文选取常用的标准测试函数,包括Ackley函数(f_1 ,最小值为0)、Rastrigin函数(f_2 ,最小值为0)、Sphere函数(f_3 ,最小值为0)、Rosenbrock函数(f_4 ,最小值为0)、Easom函数(f_5 ,最小值为0)以及Beale函数(f_6 ,最小值为-1)作为测试函数;选取粒子群算法(PSO)、遗传算法(GA)、经典Jaya算法以及已有研究中的改进Jaya算法(LJA)^[29]作为基准算法,与本文所提iJaya算法进行对比.同时考虑到智能优化算法初始赋值的随机性,求解测试函数时将每个算法独立运行50次,并记录最大值、最小值、平均值和标准差.所有算法的种群数量和迭代次数均设置为100和500;PSO算法中的 $c_1 = c_2 = 1.49$, $w = 0.8$;遗传算法中的 $p_{\text{mut}} = 0.001$, $p_{\text{cros}} = 0.9$.运行平台为Python 3.7.6,操作系统为Windows 10,64位,处理器为Intel(R) Core(TM) i5-10210U CPU,2.11 GHz,内存为12.0 GB.具体运行结果如表1所示,加粗部分为各测试函数对应的最小值.

表1 各优化算法在测试函数上的优化结果比较

函数	算法	最大值	最小值	平均值	标准差
f_1	iJaya	0.014 8	0.000 1	0.004 4	0.003 0
	LJA	9.077 3	7.596 4	8.357 1	0.364 1
	Jaya	0.289 4	0.117 3	0.174 8	0.035 6
	PSO	2.303 8	0.082 1	1.115 5	0.582 5
	GA	2.220 9	2.120 1	2.214 9	0.023 9
f_2	iJaya	0.087 2	3.51e-05	0.009 1	0.014 5
	LJA	421.372 1	345.055 6	389.893 2	16.811 1
	Jaya	301.314 5	187.078 9	236.629 7	21.037 3
	PSO	68.367 9	17.302 0	38.436 3	11.989 1
	GA	34.823 5	8.583 34	11.699 9	12.028 7
f_3	iJaya	2.17e-06	2.11e-58	5.07e-08	3.05e-07
	LJA	170.519 7	85.828 3	127.980 5	19.530 5
	Jaya	0.022 14	0.005 4	0.011 8	0.003 2
	PSO	0.071 8	0.009 5	0.029 3	0.012 9
	GA	2.18e-09	4.37e-14	4.38e-11	3.06e-10
f_4	iJaya	9.72e-28	0	5.41e-29	1.58e-28
	LJA	227 622.604 8	62 405.554 4	155 283.057 7	36 565.460 2
	Jaya	140.485 4	14.057 8	59.776 9	33.129 5
	PSO	137.333 5	27.727 8	36.794 7	18.080 4
	GA	80.100 6	0.006 1	17.460 3	31.082 7
f_5	iJaya	0	0	0	0
	LJA	1.14e-24	1.66e-29	3.23e-26	1.61e-25
	Jaya	9.45e-06	0.0	1.89e-07	1.32e-06
	PSO	2.76e-27	0.0	6.61e-29	3.89e-28
	GA	2.37e-05	5.25e-16	4.74e-07	3.31e-06
f_6	iJaya	-1.0	-1.0	-1.0	0
	LJA	-0.999 9	-1.0	-0.999 9	4.63e-15
	Jaya	-1.0	-1.0	-1.0	0
	PSO	-1.0	-1.0	-1.0	0
	GA	-0.999 9	-0.999 9	-0.999 9	1.11e-16

从表1可以看出,iJaya在测试函数 f_1 、 f_2 和 f_4 上求得的最大值、最小值、平均值以及标准差均小于其他优化算法;对于测试函数 f_3 ,iJaya求得的最大值、平均值和标准差略弱于GA,但在最小值的精度上,iJaya远优于GA;在优化测试函数 f_5 时,iJaya、Jaya和PSO均取得了全局最小值0,但在最大值、平均值和标准差的精度上,iJaya远高于Jaya和PSO,例如,iJaya的标准差为0,而Jaya和PSO的标准差分别为1.32e-06和3.89e-28,并且iJaya的4项指标值均为0,表明iJaya每次运行均能获得全局最优值;对于测试函数 f_6 ,iJaya、Jaya和PSO的结果一致,最大值、最小值和平均值均为-1,标准差为0,说明这3个算法每次运行均能获得全局最优值-1.此外,iJaya在6个测试函数上求得的最大值、最小值、平均值以及标准差均小于Jaya和LJA,表明本文改进后的Jaya算法搜索性能显著提升.在搜索性能稳定性方面,iJaya算法在除Sphere函数外的其他5个测试函数上求得的标准差均最小.由此可知,本文提出的iJaya算法具有较好的全局搜索性能,且稳定性较好.因此,本文将iJaya

用于优化SVR的超参数 C 和 γ ,以进一步提升SVR的预测能力.

2.2 混合模型

本文提出的MRMR-iJaya-SVR模型主要包括4个部分,具体如下.

1) 特征选择: 运用MRMR算法筛选出年度电力消费的关键影响因素作为预测指标. 通过MRMR算法实现特征降维,减少冗余特征对预测精度的影响.

2) 超参数优化: 利用iJaya算法优化SVR的超参数 C 和 γ . 基于iJaya算法的全局搜索能力获取SVR的最佳 C 和 γ ,以提高模型的预测能力.

3) 预测: 利用优化后的SVR对年度电力消费进行预测,得到预测结果.

4) 结果评价: 选择多个不同的评价指标对预测结果进行评价.

MRMR-iJaya-SVR模型的完整流程如图1所示.

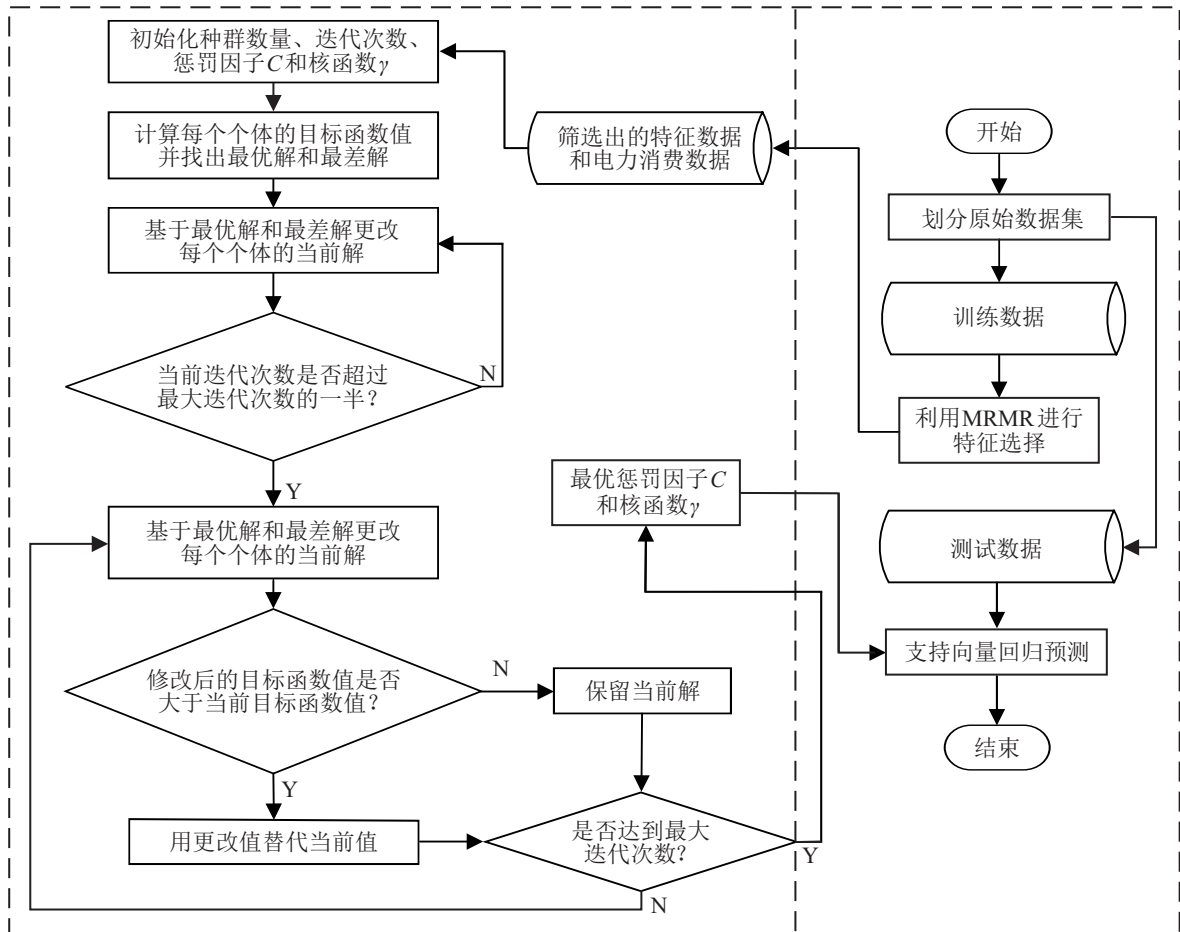


图1 MRMR-iJaya-SVR模型的流程

3 实证研究

本文选取我国的实际年度电力消费数据对MRMR-iJaya-SVR模型的预测效果进行验证. 电力消费通常受到多重因素的影响. 本文在文献分析的基础上,结合我国目前能源发展现状和相关政策,选取了经济发展水平^[30-32]、人口数量^[32]、城镇化率、产业结构、能源结构、对外贸易规模、人均可支配收入、能源强度、电力消费的一阶滞后项和二阶滞后项^[17]等10个影响因素.

3.1 数据描述

年度电力消费数据及各个影响因素的数据均来自于中国统计年鉴,时间跨度为1985年~2018年. 本

文将前80%(1985年~2012年)的数据作为训练集,用于特征选择、参数优化、拟合模型等;剩下的20%(2013年~2018年)作为测试集,用于验证模型的预测性能. 此外,为了避免不同量纲对预测结果的影响,本文对所有数据均进行归一化处理.

3.2 基准模型和评价指标

为了验证MRMR-iJaya-SVR的性能,本文选取ARIMA、HOLT、GM(1,1)、MLR、SVR、ANN、iJaya-SVR、MRMR-MLR、MRMR-SVR、MRMR-ANN作为基准模型. 选取平均绝对百分比误差(MAPE)、平均绝对误差(MAE)和均方根误差(RMSE)作为评价指标. 这3个指标的值越小,说明模型的预测精度越

高. 3个评价指标的具体表达式如下:

$$\text{MAPE} = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{n}, \quad (18)$$

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}, \quad (19)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}. \quad (20)$$

其中: y_i 表示第 i 年电力消费的实际值, \hat{y}_i 表示第 i 年电力消费的预测值, n 表示样本数量.

3.3 结果分析

所有预测模型的运行平台均为 Python 3.7.6. ARIMA 的参数 (p, d, q) 根据最小贝叶斯准则(BIC)确定; MRMR-ANN 和 ANN 的隐藏层数均为 1, 隐藏层神经元数量通过网格搜索确定; MRMR-SVR 和 SVR 的超参数 C 和 γ 也通过网格搜索的方式获得; iJaya-SVR 和 MRMR-iJaya-SVR 的超参数 C 和 γ 通过优化算法 iJaya 获得.

基于 MRMR 算法和训练集, 本文筛选出的关键影响因素为: 电力消费的一阶滞后项、进出口总额、城镇化率、人均可支配收入、电力消费的二阶滞后项、GDP 以及产业结构. 其中, 电力消费的一阶滞后项排在首位, 说明其与电力消费之间的相关性最大, 对电力消费预测非常重要. 人口数量、能源结构和能源强度未被选中, 可能的原因是上述影响因素与被筛选出的影响因素之间相关性较大, 存在冗余现象.

表 2 展示了各个模型在测试集上的预测性能, 加粗项为每列对应的最小值.

表 2 各模型在测试集上的预测性能比较

模型	MAPE/%	MAE	RMSE
ARIMA	3.07	1 846.05	2 059.40
HOLT	3.15	1 888.92	2 135.55
GM(1, 1)	10.76	6 854.42	8 032.10
MLR	2.95	1 884.84	2 145.44
ANN	2.91	1 897.19	2 534.17
SVR	1.43	887.10	987.91
iJaya-SVR	1.39	865.24	962.37
MRMR-MLR	2.66	1 705.85	1 981.03
MRMR-ANN	2.15	1 302.76	1 416.09
MRMR-SVR	1.24	798.92	1 060.87
MRMR-iJaya-SVR	0.87	527.45	722.21

从表 2 可知:

1) 与基准模型相比, 本文提出的 MRMR-iJaya-SVR 模型表现最佳. MRMR-iJaya-SVR 的 MAPE、MAE 和 RMSE 值分别为 0.87%、527.45 和 722.21, 显

著低于其他模型.

2) 与传统的 SVR 对比, 经过超参数优化后的 SVR 预测性能更好. iJaya 算法优化的 SVR 的 MAPE、MAE 和 RMSE 值分别为 1.39%、865.24 和 962.37, 均优于 SVR 对应的评价指标值 (1.43%、887.10 和 987.91), 这说明优化 SVR 的超参数有助于提升预测性能. 在经过特征选择的模型中, MRMR-iJaya-SVR 的预测精度高于 MRMR-SVR, 进一步说明了优化 SVR 超参数的必要性.

3) 与 ARIMA、HOLT、GM(1, 1) 和 MLR 相比, SVR 的 MAPE、MAE 和 RMSE 值分别降低了 51.53% ~ 86.71%、51.95% ~ 87.06% 和 52.03% ~ 87.70%. 相比于 MRMR-MLR, MRMR-SVR 的各项评价指标值分别降低了 53.38% (MAPE)、53.17% (MAE)、46.45% (RMSE). 分析其原因, 可能是因为时间序列模型和计量模型均建立在线性假设的基础上, 无法捕捉电力消费中的非线性特征, 而 SVR 可以通过核函数的方式实现非线性关系拟合.

4) 相比于 ANN, 无论是否进行特征选择, SVR 的预测效果更好. 未进行特征选择时, SVR 的 MAPE、MAE 和 RMSE 值分别降低了 50.86%、53.24% 和 61.02%; 进行特征选择后, MRMR-SVR 的 MAPE、MAE 和 RMSE 值分别降低了 42.33%、38.67% 和 25.08%. 可能的原因是 SVR 本质上是一种统计学习方法, 可以对小样本数据进行有效建模, 而 ANN 需要大量的数据来训练参数, 预测小样本时容易出现过拟合现象.

5) 无论是计量模型 (MLR) 还是机器学习模型 (ANN、SVR), 进行特征选择后, 预测精度均有提升. 其中: MAPE 值降低了 9.83% ~ 37.41%, MAE 值降低了 9.50% ~ 39.04%, RMSE 值降低了 7.66% ~ 44.12%. 需要说明的是, MRMR-SVR 的 RMSE 值较 SVR 增加了 7.39%, 但其 MAPE 和 MAE 值均低于 SVR. 因此, 本文认为 MRMR-SVR 的整体预测精度高于 SVR. 可能的原因是特征选择可以有效减少冗余特征, 达到提升预测精度的效果. 由此可见, 对于多变量预测尤其是影响因素 (特征) 较多的年度电力预测问题, 非常有必要进行影响因素筛选, 以提高预测精度.

此外, 本文还对所提模型和基准模型进行了多步预测的性能比较. 由于年度电力消费预测主要用于支持战略水平上的长远决策和规划, 参照 M4 预测比赛中年度预测的方案^[33], 本文选择 6 作为年度电力消费预测的提前期. 需要说明的是, 在提前 6 步的预测

过程中,本文假设进出口总额、城镇化率、人均可支配收入、GDP以及产业结构等5个外部变量的值为实际数据,电力消费量的滞后项为前两年的预测值.因为本文的主要目的是验证模型的预测性能,若使用影响因素的预测值将会给模型比较带来新的不确定性^[34].本文采取的多步预测策略为迭代策略.

表3展示了各模型提前6步预测的性能比较结果,加粗项为每列对应的最小值.

表3 各模型提前6步的预测性能比较

模型	MAPE/%	MAE	RMSE
ARIMA	2.73	1 696.10	2 052.43
HOLT	3.16	2 027.42	2 636.95
GM(1,1)	10.92	7 048.43	8 480.76
MLR	3.68	2 365.59	27 62.06
ANN	7.03	4 565.62	5 807.73
SVR	1.48	923.59	1 064.66
iJaya-SVR	1.44	898.67	1 032.77
MRMR-MLR	3.36	2 165.98	2 571.88
MRMR-ANN	2.20	1 311.00	1 410.66
MRMR-SVR	1.19	770.17	1 053.73
MRMR-iJaya-SVR	1.02	619.26	779.11

由表3可知,MRMR-iJaya-SVR的预测性能最好,其MAPE、MAE和RMSE值分别为1.02%、619.26和779.11,这表明本文所提模型在多步预测的情况下仍然能够保持较高的精度,具有良好的可靠性.在所有模型中,ANN的表现最差,可能的原因是ANN预测小样本数据时容易出现过拟合,导致在多步预测时出现误差累积.

从表3还可以发现一些与单步预测一致的结论.

1) 经过超参数优化后的SVR的预测精度有所提升.例如,iJaya-SVR(MRMR-iJaya-SVR)模型的3项

评价指标值均优于SVR(MRMR-SVR)模型.

2) 经过特征选择后,各模型的预测精度明显提升.其中:ANN的提升幅度最大,其MAPE、MAE和RMSE值分别降低了68.71%、71.29%和75.71%,MLR的提升幅度最小,其MAPE、MAE和RMSE值分别降低了8.70%、8.44%和6.89%.主要是因为减少特征可以有效降低ANN的模型复杂度,进而在一定程度上降低过拟合,提升泛化能力;但对于MLR而言,减少特征无法改变其线性本质,故误差降低的幅度有限.

3) 与时间序列模型ARIMA、HOLT和灰色预测模型GM(1,1)相比,SVR的预测效果更好.上述结论进一步体现了优化SVR超参数及特征选择的必要性.

3.4 进一步分析

为了验证所提预测模型的鲁棒性,本文还选择了北京市1990年~2019年的年度电力消费数据进行建模分析.参考文献[17],从经济发展水平、城镇化水平、工业化水平、人口数量、产业结构、居民消费水平、用电基数等维度选取了10个特征,具体包括:国内生产总值(GDP)、人均GDP、工业增加值、人口数量、城镇化率、第二产业GDP占比、第三产业GDP占比、居民消费指数、滞后一期的电力消费量以及滞后两期的电力消费量.预测北京市年度电力消费时的实施步骤与上述完全一致.经过MRMR算法挑选出的特征包括:工业增加值、第二产业GDP占比、人均GDP以及滞后一期的电力消费量.所提模型和基准模型的预测性能如表4所示,加粗项为每列对应的最小值.

表4 各模型的预测性能比较(北京市)

模型	单步			提前6步		
	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE
ARIMA	2.16	227 327.51	245 643.28	1.92	196 455.56	227 442.23
HOLT	2.68	281 098.41	319 930.04	2.07	210 405.07	241 318.97
GM(1,1)	12.88	1 324 893.28	1 344 178.09	25.38	2 709 082.48	2 845 841.84
MLR	8.15	897 784.72	1 081 739.70	8.26	910 137.22	1 097 280.10
ANN	8.11	893 296.31	1 076 560.47	8.22	905 727.97	1 092 192.14
SVR	1.97	209 567.60	231 638.23	2.00	214 162.35	247 150.13
iJaya-SVR	1.87	198 163.67	219 324.98	1.89	200 773.07	232 552.20
MRMR-MLR	2.05	209 669.40	238 938.01	3.48	359 461.7	379 665.10
MRMR-ANN	1.53	156 263.95	172 375.21	1.46	146 622.40	184 211.06
MRMR-SVR	1.17	120 640.25	143 479.23	1.25	129 730.97	151 497.51
MRMR-iJaya-SVR	0.98	102 748.38	117 924.33	0.94	97 723.95	108 826.77

从表4可以看出,MRMR-iJaya-SVR模型在单步预测和多步预测中的预测效果仍然是最好的,说明其

具有较好的鲁棒性.此外,经过特征选择后的模型预测精度均得到有效提升,再次论证了特征选择有助于

改善预测效果的结论. 进一步对比发现, 无论是否进行特征选择, 经过超参数优化的SVR的预测效果均优于未经过超参数优化的SVR, 说明了超参数优化对于提高SVR预测精度的重要性. 综上, 可以发现, 预测北京市年度电力消费得出的结论与预测全国年度电力消费得出的结论具有一致性.

4 结论

针对年度电力消费样本少、影响因素众多以及影响因素之间关系复杂等特点, 本文提出了基于特征选择和iJaya-SVR的年度电力消费预测模型(MRMR-iJaya-SVR), 并使用我国的年度电力消费数据对其进行实证分析. 本文的研究结论如下: 1) 特征选择有助于提高年度电力消费的预测精度; 2) 优化SVR超参数有助于提升SVR的预测性能; 3) 与基准模型相比, 本文提出的MRMR-iJaya-SVR模型在单步预测和多步预测中的表现均更好; 4) 本文提出的MRMR-iJaya-SVR模型具有良好的鲁棒性.

虽然本文提出的混合模型MRMR-iJaya-SVR表现出较好的预测性能, 但仍有值得进一步探索的地方. 例如, 运用MRMR选择特征时与预测模型无关, 无法保证所选特征在特定预测模型中一定是最优的, 在未来的研究中可尝试将预测模型加入特征选择过程.

参考文献(References)

- [1] IEA. 2050年净零排放[R]. Paris: IEA, 2021. (IEA. Net zero by 2050[R]. Paris: IEA, 2021.)
- [2] Kaytez F. A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption[J]. Energy, 2020, 197: 117200.
- [3] Macaira P M, Sousa R C, Oliveira F L C. Forecasting Brazil's electricity consumption with Pegels Exponential Smoothing Techniques[J]. IEEE Latin America Transactions, 2016, 14(3): 1252-1258.
- [4] Mohamed Z, Bodger P. Forecasting electricity consumption in New Zealand using economic and demographic variables[J]. Energy, 2005, 30(10): 1833-1843.
- [5] Bianco V, Manca O, Nardini S. Electricity consumption forecasting in Italy using linear regression models[J]. Energy, 2009, 34(9): 1413-1421.
- [6] Duran Toksari M. Ant colony optimization approach to estimate energy demand of Turkey[J]. Energy Policy, 2007, 35(8): 3984-3990.
- [7] Hamzaçebi C. Forecasting of Turkey's net electricity energy consumption on sectoral bases [J]. Energy Policy, 2007, 35(3): 2009-2016.
- [8] Ekonomou L. Greek long-term energy consumption prediction using artificial neural networks[J]. Energy, 2010, 35(2): 512-517.
- [9] Ardakani F J, Ardehali M M. Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types[J]. Energy, 2014, 65: 452-461.
- [10] Kavaklioglu K. Modeling and prediction of Turkey's electricity consumption using support vector regression[J]. Applied Energy, 2011, 88(1): 368-375.
- [11] Hong W C. Electric load forecasting by support vector model[J]. Applied Mathematical Modelling, 2009, 33(5): 2444-2454.
- [12] Vapnik V. The nature of statistical learning theory[M]. Springer science & business media, 1999.
- [13] Wang J J, Li L, Niu D X, et al. An annual load forecasting model based on support vector regression with differential evolution algorithm[J]. Applied Energy, 2012, 94: 65-70.
- [14] 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(3): 417-425.
- [15] 董景荣. 基于因素影响的电力消费预测研究[J]. 运筹与管理, 2000, 9(2): 25-30. (Dong J R. Study of electricity consumption forecasting based on influencing factors[J]. Operations Research and Management Science, 2000, 9(2): 25-30.)
- [16] 李菁, 马彦琳, 梁晓群. 基于基因表达式编程的电力消费预测模型——武汉市的实证[J]. 统计研究, 2008, 25(4): 45-49. (Li J, Ma Y L, Liang X Q. Study on the electricity consumption forecasting model based on gene expression programming[J]. Statistical Research, 2008, 25(4): 45-49.)
- [17] 张运厚, 李婉莹, 董福贵. 基于DE-GWO-SVR的中长期电力需求预测[J]. 中国电力, 2021, 54(9): 83-88. (Zhang Y H, Li W Y, Dong F G. Medium and long-term power demand forecasting based on DE-GWO-SVR[J]. Electric Power, 2021, 54(9): 83-88.)
- [18] 何晓萍, 刘希颖, 林艳苹. 中国城市化进程中的电力需求预测[J]. 经济研究, 2009, 44(1): 118-130. (He X P, Liu X Y, Lin Y P. China's electricity demand forecast under urbanization process[J]. Economic Research Journal, 2009, 44(1): 118-130.)
- [19] Got A, Moussaoui A, Zouache D. Hybrid filter-wrapper feature selection using whale optimization algorithm: A multi-objective approach[J]. Expert Systems with

- Applications, 2021, 183: 115312.
- [20] 李郅琴, 杜建强, 聂斌, 等. 特征选择方法综述[J]. 计算机工程与应用, 2019, 55(24): 10-19.
(Li Z Q, Du J Q, Nie B, et al. Summary of feature selection methods[J]. Computer Engineering and Applications, 2019, 55(24): 10-19.)
- [21] Peng H C, Long F H, Ding C. Feature selection based on mutual information: Criteria of max-dependency, max-relevance, and min-redundancy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238.
- [22] 范雪莉, 冯海泓, 原猛. 基于互信息的主成分分析特征选择算法[J]. 控制与决策, 2013, 28(6): 915-919.
(Fan X L, Feng H Y, Yuan M. PCA based on mutual information for feature selection[J]. Control and Decision, 2013, 28(6): 915-919.)
- [23] 韩敏, 刘晓欣. 一种基于互信息变量选择的极端学习机算法[J]. 控制与决策, 2014, 29(9): 1576-1580.
(Han M, Liu X X. An extreme learning machine algorithm based on mutual information variable selection[J]. Control and Decision, 2014, 29(9): 1576-1580.)
- [24] Vapnik V N. Statistical learning theory[M]. New York: Wiley, 1998.
- [25] 林玲, 陈福集, 谢加良, 等. 基于改进灰狼优化支持向量回归的网络舆情预测[J]. 系统工程理论与实践, 2022, 42(2): 487-498.
(Lin L, Chen F J, Xie J L, et al. Prediction of network public opinion based on improved grey wolf optimized support vector machine regression[J]. Systems Engineering—Theory & Practice, 2022, 42(2): 487-498.)
- [26] 张新生, 张琪. 基于改进RFFS和GSA-SVR的长输油管道腐蚀深度预测研究[J]. 系统工程理论与实践, 2021, 41(6): 1598-1610.
(Zhang X S, Zhang Q. Research on prediction of corrosion depth of long oil pipelines based on improved RFFS and GSA-SVR[J]. Systems Engineering—Theory & Practice, 2021, 41(6): 1598-1610.)
- [27] De Carvalho F d A T, Lima Neto E d A, Ferreira M R P. A robust regression method based on exponential-type kernel functions[J]. Neurocomputing, 2017, 234: 58-74.
- [28] Venkata R R. Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems[J]. International Journal of Industrial Engineering Computations, 2016, 7(1): 19-34.
- [29] Iacca G, dos Santos J V C, Veloso de M V. An improved Jaya optimization algorithm with Lévy flight[J]. Expert Systems with Applications, 2021, 165: 113902.
- [30] 李科. 我国经济增长对电力消费的阈值效应分析[J]. 中国软科学, 2011(7): 31-41.
(Li K. The Threshold effect of China's economic growth on electricity consumption[J]. China Soft Science, 2011(7): 31-41.)
- [31] 隋建利, 米秋吉, 刘金全. 异质性能源消费与经济增长的非线性动态驱动机制[J]. 数量经济技术经济研究, 2017, 34(11): 24-43.
(Sui J L, Mi Q J, Liu J Q. The nonlinear dynamic drive mechanism between heterogeneous energy consumption and economic growth[J]. The Journal of Quantitative & Technical Economics, 2017, 34(11): 24-43.)
- [32] 林伯强. 结构变化、效率改进与能源需求预测——以中国电力行业为例[J]. 经济研究, 2003(5): 57-65.
(Lin B Q. Structural changes, efficiency improvement and electricity demand forecasting[J]. Economic Research Journal, 2003(5): 57-65.)
- [33] Makridakis S, Spiliotis E, Assimakopoulos V. The M4 Competition: 100 000 time series and 61 forecasting methods[J]. International Journal of Forecasting, 2020, 36(1): 54-74.
- [34] Lehna M, Scheller F, Herwartz H. Forecasting day-ahead electricity prices: A comparison of time series and neural network models taking external regressors into account[J]. Energy Economics, 2022, 106: 105742.

作者简介

高锋(1995—), 男, 博士, 从事时间序列预测、能源大数据分析等研究, E-mail: gaofeng@pku.edu.cn;

邵雪焱(1978—), 女, 副研究员, 博士, 从事风险管理、应急管理研究, E-mail: xyshao@casisd.cn.