



УДК 681.513.5:621.311

Н. Д. Поляхов, И. А. Приходько, Ван Ефэн
Санкт-Петербургский государственный электротехнический
университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

Прогнозирование электропотребления на основе метода опорных векторов

Изменение электрической нагрузки представляет собой нестационарный случайный процесс, зависящий от многих факторов. Предлагается обрабатывать исходные данные наблюдений с помощью метода главных компонент, что позволяет уменьшить размерность обучающей выборки. Для прогнозирования электропотребления выбран метод опорных векторов. Преимуществом метода является то, что параметры регрессионной модели определяются на основе решения задачи квадратичного программирования, имеющей единственное решение. Оптимизация параметров ядерной функции выполнена на основе роя частиц. Исследования моделированием подтверждают эффективность предложенного подхода.

Оптимизация, прогнозирование электропотребления, метод опорных векторов, алгоритм роя частиц

Прогнозирование электропотребления является основой надежного функционирования электроэнергетической системы (ЭЭС). Нагрузка ЭЭС формируется комплексом потребителей электроэнергии, состоящих из промышленных предприятий, сельского и жилищно-коммунального хозяйств. При оперативном управлении режимами используется оперативный прогноз графика потребления на следующие и оставшиеся до конца суток часы.

Повышение точности прогнозирования обеспечивает экономию энергетических ресурсов, определяет эффективность управления электроснабжением и соответствующее увеличение прибыли энергетических предприятий.

Прогнозы электропотребления закладываются в инвестпрограммы энергокомпаний. По оценкам российских специалистов, каждая оплошность в ежегодном прогнозе электропотребления на 1 % – это 4 млрд дол. дополнительных инвестиций на возведение генерирующих мощностей¹.

Развитие рыночных отношений в управлении электроэнергетикой привело к появлению противоречия между рыночными конкурентными механизмами функционирования отдельных подсистем электроэнергетических систем и требованиями обеспечения надежности и качества работы ЭЭС как единого комплекса.

Задачей исследования является увеличение точности предсказания предполагаемого потребления электроэнергии с целью оптимального использования энергоресурсов, минимизации стоимости и повышения надежности электроснабжения.

Прогнозирование временного ряда сводится к типовой задаче – аппроксимации функции многих переменных по заданному набору примеров с помощью процедуры погружения ряда в многомерное пространство.

Задача прогнозирования формулируется следующим образом: зная предыдущие q значений временного ряда, предсказать последующее значение $x(t+d)$: $x(t+d) = f(x(t), \dots, x(t-q+1), \eta_1, \eta_2, \dots, \eta_g)$, где d – шаг прогнозирования; g – количество независимых переменных η .

Для формирования обучающей последовательности временной ряд разбивается на окна шириной q :

¹ Цена расточительности / Е. Рудаков, Ю. Саакян, Б. Нигматулин, Н. Прохорова // Электрон. журн. энергосервисной компании «Экологические системы». 2008. № 7, июль. URL: <http://www.w3.org>.

$$\left\{ \begin{array}{l} x(t-q+1), \dots, x(t-1), x(t); \\ x(t-q+2), \dots, x(t), x(t+1); \\ \dots \\ x(t-q+1+j), \dots, x(t-1+j), x(t+j). \end{array} \right\}$$

Обучающая последовательность при этом выглядит следующим образом:

$$x(t-q+1+j), \dots, x(t-1+j), x(t+j) \rightarrow x(t+d+j).$$

Введение дополнительных признаков. Из рассмотрения процесса прогнозирования с позиций теории распознавания образов можно утверждать, что введение дополнительных признаков способствует повышению точности прогноза.

В обучающую выборку вводятся дополнительные значения нагрузки в прошлые дни D , в прогнозируемый час $t+d$:

$$\left\{ \begin{array}{l} x(D, t-q+1), \dots, x(D, t); \\ x(D-1, t+d), \dots, x(D-v, t+d); \\ x(D, t-q+2), \dots, x(D, t-1); \\ x(D-1, t+d+1), \dots, x(D-v, t+d+1); \\ \dots \\ x(D, t-q+1+j), \dots, x(D, t-1+j); \\ x(D-1, t+d+j), \dots, x(D-v, t+d+j). \end{array} \right\}$$

Нормирование обучающей выборки выполняется предварительную обработку данных для обучения сети посредством нормирования входов и выходов так, чтобы они находились в установленном диапазоне $[0, 1]$:

$$\tilde{x}_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}}.$$

Для улучшения точности прогнозирования электропотребления дополнительно использован метод главных компонент. Преобразование по этому методу позволяет заменить большое количество информации, основанной на взаимно коррелирующих входных данных, множеством статистически независимых компонентов с учетом их важности.

Для ковариационной матрицы входных данных x : $\lambda_1 > \lambda_2 > \dots \lambda_q \geq 0$ – собственные числа; u_1, u_2, \dots, u_q – соответствующие им собственные векторы; q – размерность входного вектора; p – число образов. Метод главных компонент состоит в нахождении линейных комбинаций исходных переменных

$$y_i = u_{i1}x_1 + u_{i2}x_2 + \dots + u_{iq}x_q, \quad i = \overline{1, s}, \quad s < q.$$

Переменные y_i упорядочены по возрастанию дисперсии. Большую часть общей дисперсии характеризует подмножество s первых переменных. Относительные доли дисперсии исходных данных [%]

$$\text{определяются по формуле } \lambda_i \cdot 100 / \sum_{i=1}^q \lambda_i.$$

Для выбора числа главных компонент использован график зависимости собственных значений λ_i от числа главных компонент, принято $s = 6$.

Метод опорных векторов – набор алгоритмов вида «обучение с учителем», используемых для задач классификации и регрессионного анализа [1]–[3].

К преимуществам метода опорных векторов относится то, что параметры регрессионной модели определяются на основе решения задачи квадратичного программирования.

Задачей построения уравнения линейной регрессии является оценка неизвестной вещественной функции

$$y = f(x) + \varepsilon, \quad (1)$$

где $f(x) = \langle w, x \rangle + w_0$, вектор $w = (w_1, \dots, w_n) \in R^n$ и смещение $w_0 \in R$ – параметры уравнения; ε – допустимая ошибка аппроксимации; для задачи (1) $y = x(t+d)$.

В методе опорных векторов задача построения нелинейной регрессии в исходном пространстве X рассматривается как задача построения линейной регрессии в некотором расширенном пространстве признаков H , порождаемом нелинейным отображением $\varphi: X \rightarrow H$:

$$f(x) = \langle w, \varphi(x) \rangle + w_0.$$

Задача нахождения параметров сводится к задаче квадратичной оптимизации и формулируется в виде минимизации функционала [1], [2]:

$$\min_{w, w_0, \xi, \xi^*} \left[\frac{1}{2} w^T w + C \sum_{i=1}^p (\xi_i + \xi_i^*) \right] \quad (2)$$

при ограничениях

$$\begin{aligned} y_i - w^T x_i - w_0 &\leq \varepsilon + \xi_i, \quad w^T x_i + w_0 - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i &\geq 0, \quad \xi_i^* \geq 0, \quad i = \overline{1, p}, \end{aligned}$$

где параметр C – положительная константа, задающая штраф на ошибку; $\xi_i > 0$ – набор дополнительных переменных, характеризующих ошибку на объектах \mathbf{x}_i , $i = 1, \dots, p$ (рис. 1). Штрафное

слагаемое в функционале $\frac{1}{2}\|\mathbf{w}\|^2$ вводится со-

гласно принципу регуляризации и означает, что среди всех векторов \mathbf{w} , минимизирующих функционал (2), наиболее предпочтительны векторы с минимальной нормой. Второе слагаемое функционала штрафует любые отклонения $f(\mathbf{x})$ от y больше, чем ε для всех обучающих данных.

Функция потерь

$$L_{\varepsilon}(y_i) = \begin{cases} 0, & |f(\mathbf{x}_i) - y_i| < \varepsilon; \\ |f(\mathbf{x}_i) - y_i| - \varepsilon, & |f(\mathbf{x}_i) - y_i| \geq \varepsilon \end{cases}$$

отображена на рис. 1.

При использовании метода опорных векторов, как правило, решается двойственная задача

$$\min_{\alpha_i, \alpha_i^*} \frac{1}{2} \sum_{i,j=1}^p (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \mathbf{x}_i^T \mathbf{x}_j - y_i \times \\ \times \sum_{i=1}^p (\alpha_i - \alpha_i^*) + \varepsilon \sum_{i=1}^p (\alpha_i + \alpha_i^*)$$

с ограничениями

$$\begin{cases} \sum_{i=1}^p (\alpha_i - \alpha_i^*) = 0; \\ \alpha_i, \alpha_i^* \in [0, C], \end{cases}$$

где α_i, α_i^* – множители Лагранжа.

Минимум функции Лагранжа по переменным определяется условиями Куна–Таккера [1]–[3].

Уравнение регрессии выражается через двойственные переменные:

$$f(\mathbf{x}_i) = \sum_{i=1}^p (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + w_0,$$

где $K(\mathbf{x}_i, \mathbf{x})$ – ядерная функция. В исследованиях в качестве ядерной функции использована гауссова радиальная базисная функция

$$K(\mathbf{x}_i, \mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}\|^2}{2\sigma^2}\right).$$

Ограничение использования метода опорных векторов связано с отсутствием рекомендаций по выбору параметров ядерной функции, наиболее подходящих для решения конкретной задачи.

Подбор управляющего параметра алгоритма C (отношение между эмпирическим риском и сложностью модели) может повлиять на способность к обобщению модели.

Для определения параметра C и параметров ядерной функции в работе предлагается использовать оптимизационный алгоритм *роя частиц*. Метод является стохастическим, не требующим вычисления градиента. В качестве оптимизируемой функции использована ошибка прогнозирования.

Алгоритм осуществляет передвижение частиц в пространстве поиска. Частицы передвигаются с определенной скоростью до тех пор, пока не будет найдена позиция глобального оптимума.

Лучшая позиция i -й частицы в пространстве поиска вычисляется в соответствии с формулами:

$$\begin{aligned} v_i(t+1) &= wv_i(t) + c_1\eta_1(\mathbf{p}_{bi}(t) - \\ &- x_i(t)) + c_2\eta_2(\mathbf{p}_{gi}(t) - x_i(t)), \\ x_i(t+1) &= x_i(t) + \beta v_i(t+1), \end{aligned}$$

где $w = \text{const}$ – инерционный вес; $v_i(t)$ – текущая скорость i -й частицы в момент t ; постоянный множитель c_1 – ускорение с положительными значениями, локальная весовая доля; вектор \mathbf{p}_{bi} – луч-




Рис. 1

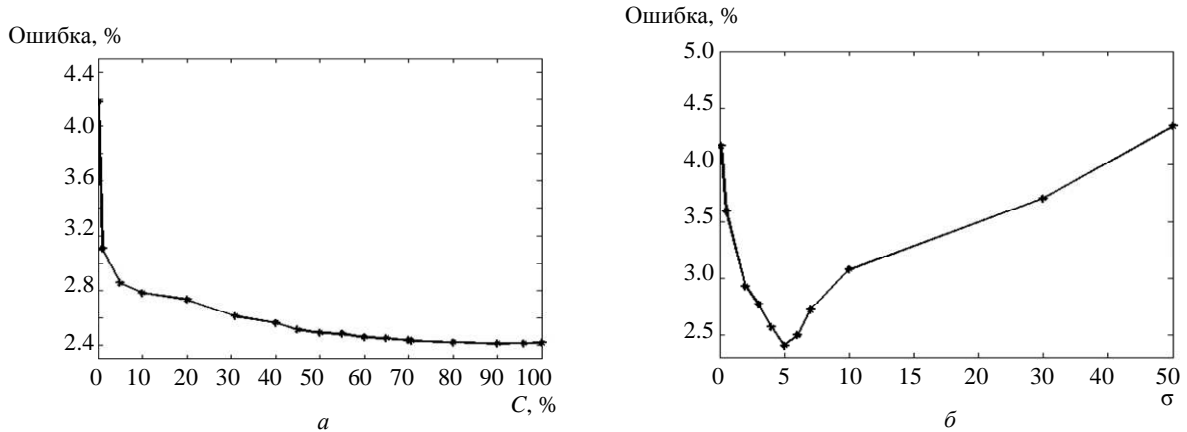


Рис. 2

шая позиция i -й частицы; $x_i(t)$ – текущая позиция i -й частицы; $c_2 = \text{const}$ – оптимальный весовой коэффициент; p_{gi} – лучшая позиция роя частиц; β – фактор ограничения, используемый для контроля веса скорости.

Расчет вектора скорости i -й частицы на $(t+1)$ -м шаге вычисляется в соответствии со следующими формулами:

$$\begin{aligned} v_i(t+1) &= wv_i(t) + c_1r_1(p_{bi}(t) - x_i(t)) + \\ &+ c_2r_2(p_{gi}(t) - x_i(t)), \\ x_i(t+1) &= x_i(t) + \beta v_i(t+1), \end{aligned}$$

где $w = \text{const}$ – инерционный вес; $v_i(t)$ – текущая скорость i -й частицы в момент t . Постоянный множитель $c_1 = \text{const}$ характеризует ускорение с положительными значениями (локальная весовая доля), задано 1.5. Множители r_1, r_2 являются случайными переменными в диапазоне $[0, 1]$. Вектор $p_{bi}(t)$ – это лучшая позиция i -й частицы, а вектор $x_i(t)$ – текущая позиция i -й частицы:

$$p_{bi}(t) = \begin{cases} p_{bi}(t-1) & f(x_i(t)) \geq f(p_{bi}(t-1)); \\ x_i(t) & f(x_i(t)) \leq f(p_{bi}(t-1)). \end{cases}$$

Зависимости ошибки от параметра алгоритма C и параметра ядерной функции σ приведены на рис. 2, a и b . Оптимальное значение кусочно-линейной функции потерь равно 0.02. При уменьшении и увеличении значения функции потерь точность ухудшается.

В исследовании моделированием использована обучающая выборка часовых данных электропотребления за рабочие дни летнего периода 2009 г. города Сюй Джоу (КНР). Максимальный разброс данных электропотребления составляет 130 %.

Исследование моделированием выполнено с использованием пакета MATLAB R2009b и программы SVR [5]. Результаты прогнозирования электропотребления приведены в таблице, иллюстрацией результатов служит рис. 3, где обозначены: линия 1 – график фактической нагрузки; линия 2 – прогноз; линия 3 – прогноз (при формировании обучающей выборки использован метод главных компонент).




Рис. 3

Метод	Параметр		Ошибка прогноза, %
	σ	C	
Метод опорных векторов (рис. 3, а)	13	65	3.34
Метод опорных векторов + метод роя частиц (рис. 3, б)	6	55	2.9
Метод опорных векторов + метод роя частиц + метод главных компонент (рис. 3, в)	6	55	2.4

Лучший результат получен для модели оптимизации с помощью метода роя частиц при использовании метода главных компонент. Точность прогноза по сравнению с моделированием на основе статистических методов [5] улучшилась на 3.6 %.

В заключение можно сказать следующее:

1. В способе формирования обучающей выборки для повышения точности прогноза наиболее эффективны уменьшение размерности исход-

ных данных с использованием метода главных компонент, индикация времени суток, дополнительное введение значений нагрузки в прошлые дни в прогнозируемый час. Каждое из этих мероприятий обеспечивает уменьшение ошибки прогноза на 0.5–1 %. Применение нормирования обучающей выборки позволило снизить ошибку на 0.3–0.5 %.

2. Модель прогнозирования электрической нагрузки на основе метода опорных векторов, включающая предварительную обработку исходных данных, программу оптимизации выбора параметров ядерной функции на основе алгоритма роя, позволяет улучшить прогноз более, чем на 3 %.

Точность прогнозирования зависит от типа электрической нагрузки. При разбросе данных обучающей выборки 130 % точность прогноза составила 2.4 %.

СПИСОК ЛИТЕРАТУРЫ

1. Vapnik V., Chapelle O. Bounds on error expectation for support vector machines // Neural Computation. 2000. Vol. 12, № 9. P. 2013–2036.

2. Воронцов К. В. Лекции по методу опорных векторов. 2007. URL: <http://machinelearning.ru/>.

3. Smola A., Schoelkopf B. A tutorial on support vector regression: Tech. Rep. NeuroCOLT2 NC2-TR-1998-030: 1998. URL: <http://citeseer.ist.psu.edu/smola98tutorial.html>.

4. Gunn S. R. Support vector machines for classification and regression / Technical report faculty of engineering, science and mathematics school of electronics and computer science. University of Southampton. 1998. 10 May. 54 p.

5. Оценка эффективности интеллектуальных и классических моделей краткосрочного прогнозирования электропотребления / Н. Д. Поляхов, И. А. Приходько, Е. С. Анушина, Ван Ефэн // Естественные и технические науки. 2011. № 3. С. 304–309.

N. D. Polyakhov, I. A. Prikhodko, Van Efen

Saint-Petersburg state electrotechnical university «LETI»

ELECTRIC LOAD FORECASTING BASED ON SUPPORT VECTOR MACHINE OPTIMIZED

Changing electrical load is a stationary stochastic process depending on many factors. To handle the raw observational data is using support vector machines to reduce the dimension of the training set. To predict power consumption method is chosen support vector machines. Advantage of this method is that the parameters of the regression model are based on quadratic programming problem having a unique solution. Optimizing parameters of kernel functions implemented based on particle swarm optimization algorithm. Research on the simulation confirm the efficiency of the proposed approach.

Optimization, prediction of power consumption, the method of support vector machines, particle swarm optimization algorithm.