

**Е. В. Бурнаев, М. Г. Беляев, Ю. Н. Свириденко, С. С. Чернова** (Москва, ИППИ РАН, ЦАГИ, ИСА РАН). **О методах построения консолидированных данных.**

Пусть  $M_1$  и  $M_2$  — некоторые модели, задающие функции  $y^{(1)} = f_{M_1}(\mathbf{x})$ ,  $\mathbf{x} \in \mathbf{R}^m$ ,  $y^{(1)} \in \mathbf{R}^1$  и  $y^{(2)} = f_{M_2}(\mathbf{x})$ ,  $\mathbf{x} \in \mathbf{R}^m$ ,  $y^{(2)} \in \mathbf{R}^1$ , и используемые для того, чтобы моделировать один и тот же физический процесс. Будем считать, что для заданного входа в случае модели  $M_2$  подсчитать соответствующий выход «дороже» (например, в смысле времени вычислений), чем в случае модели  $M_1$ , при этом модель  $M_2$  точнее модели  $M_1$ . Задана выборка  $D_N = \{\mathbf{x}_i, y_i^{(2)}\}_{i=1}^N$  значений модели  $M_2$ . Предположим, что объем  $N$  этой выборки недостаточен ( $M_2$  — «дорогая» модель) для того, чтобы построить надежную метамодель [2] для модели  $M_2$ . Задача состоит в том, чтобы, используя выборку  $D_N$  и «знания», содержащиеся в модели  $M_1$ , построить метамодель  $\widehat{y}^{(2|1)} = \widehat{f}_{\widehat{M}_2|M_1}(\mathbf{x}|f_{M_1}(\mathbf{x}))$ ,  $\mathbf{x} \in \mathbf{R}^m$ ,  $y^{(2|1)} \in \mathbf{R}^1$ , которая аппроксимирует модель  $M_2$  лучше, чем аппроксиматор, построенный только по данным  $D_N$ . Метамодель  $\widehat{M}_2|M_1$  позволяет учесть информацию о физическом процессе, которая содержится в неточной модели  $M_1$ , при построении метамодели для более точной модели  $M_2$  и, тем самым, является результатом консолидации разноточных данных.

Известно, что если  $\xi$  и  $\eta$  — две гауссовские случайные величины, то оптимальный в среднеквадратичном прогноз значения  $\xi$  при фиксированном значении  $\eta$  задается условным математическим ожиданием, имеющим структуру  $\mathbf{E}(\xi|\eta) = a\eta + b$ . Зачастую для моделирования многомерных зависимостей используются гауссовские процессы [3], т. е. предполагается, что моделируемая функция  $f(\mathbf{x})$  является реализацией гауссовского процесса. Именно поэтому будем «искать» метамодель  $\widehat{M}_2|M_1$  в виде

$$\widehat{y}^{(2|1)} = \widehat{f}_{\widehat{M}_2|M_1}(\mathbf{x}|\widehat{f}_{M_1}(\mathbf{x})) = \rho(\mathbf{x})f_{M_1}(\mathbf{x}) + \delta(\omega(\mathbf{x})),$$

где функции  $\rho(\mathbf{x})$  и  $\delta(\omega(\mathbf{x}))$  моделируются разложениями по адаптивному базису [1], а именно,  $\rho(\mathbf{x}) = \sum_{k=1}^{p_\rho} c_{k,\rho} \psi_k^\rho(\mathbf{x})$ ,  $\delta(\omega(\mathbf{x})) = \sum_{k=1}^{p_\delta} c_{k,\delta} \psi_k^\delta(\omega(\mathbf{x}))$ , где  $\psi_k^\rho(\mathbf{x}) = \varphi(\gamma_k^\rho, \mathbf{x})$  и  $\psi_k^\delta(\omega(\mathbf{x})) = \varphi(\gamma_k^\delta, \omega(\mathbf{x}))$  — адаптивные базисные функции, например,  $\varphi(\gamma_k^\rho, \mathbf{x}) = 1/(1 + \exp(\sum_{i=1}^m \gamma_{k,i}^\rho x^i))$  (сигмоидная функция),  $\omega(\mathbf{x})$  — какой-либо входной вектор, содержащий информацию о локальном поведении функции  $f_{M_1}(\mathbf{x})$ , например,  $\omega(\mathbf{x}) = (x^1, x^2, \dots, x^p, \|\nabla f_{M_1}(\mathbf{x})\|)$ . Отметим, что напрямую получение локальной информации о поведении функции  $f_{M_1}(\mathbf{x})$  может быть затруднено. В то же время построение метамодели для модели  $M_1$ , например, на основе разложения по адаптивному базису, позволяет легко оценить локальное поведение функции  $f_{M_1}(\mathbf{x})$ , поскольку в таком случае подсчеты уже будут производиться с использованием явных формул.

Для оценки параметров метамодели  $\widehat{M}_2|M_1$  необходимо решить оптимизационную задачу

$$\min_{\{c_{k,\rho}, \gamma_k^\rho\}_{k=1}^{p_\rho}, \{c_{k,\delta}, \gamma_k^\delta\}_{k=1}^{p_\delta}} \sum_{i=1}^N \|y_i^{(2)} - \rho(x_i)f_{M_1}(x_i) - \delta(\omega(x_i))\|^2.$$

В силу того, что функции  $\rho(\mathbf{x})$  и  $\delta(\omega(\mathbf{x}))$  линейно зависят от коэффициентов  $\{c_{k,\rho}\}_{k=1}^{p_\rho}$ ,  $\{c_{k,\delta}\}_{k=1}^{p_\delta}$ , для решения оптимизационной задачи можно использовать гибридный алгоритм, разработанный в [1].

Работа выполнена при финансовой поддержке грантов РФФИ (проекты № 09-01-00584а, № 09-07-00180а).

## СПИСОК ЛИТЕРАТУРЫ

1. *Burnaev E. V., Belyaev M. G., Prihodko P. V., Chernova S. S.* Neural approximation based on regression and boosting. — В сб.: Математические методы в теории надежности. Теория. Методы. Приложения. VI Международная конференция MMR 2009 (Москва, 22–29 июня 2009 г.). М: РУНГ и др., с. 120–124. <http://mmr.gubkin.ru/etc/MMR2009.pdf>.
2. *Forrester A., Sobester A., Keane A.* Engineering Design via Surrogate Modelling. A Practical Guide. Chichester etc: Wiley, 2008.
3. *Rasmussen C. E., Williams C. K. I.* Gaussian processes for machine learning. Cambridge, MA: MIT Press, 2006.