

УДК 519.6+681.51
DOI: 10.18799/29495407/2024/4/76
Шифр специальности ВАК: 2.3.5

Оптимизация параметров гибридного алгоритма прогнозирования с использованием ансамбля моделей в режиме реального времени

Е.А. Кочегурова[✉], С.М. Сайберт, К.В. Татьянакина

Национальный исследовательский Томский политехнический университет, Россия, г. Томск

[✉]kochev@tpu.ru

Аннотация. Целью данной работы является развитие технологий ансамблевого или мульти моделирования для оптимизации параметров модели прогнозирования. Предлагаемая модель прогнозирования в виде рекуррентного штрафного сплайна (P-сплайн) имеет несколько настраиваемых параметров, что обеспечивает адаптивность модели для предсказания поведения временного ряда по его ретроспективным значениям. Создание ансамбля моделей в классе варьируемых параметров P-сплайна является исходной информацией для продольной кластеризации временного ряда. Подобный подход позволяет оценить вдоль временной оси центры кластеров, которые и соответствуют оптимальным значениям параметров модели на выбранном сегменте временного ряда в режиме реального времени. Это позволило повысить эффективность рекуррентного P-сплайна как модели прогнозирования в реальном времени, сократить вычислительные затраты и увеличить быстродействие алгоритмов прогнозирования.

Ключевые слова: прогнозирование в реальном времени, штрафной P-сплайн, ансамблевое моделирование, показатели эффективности, плотностная кластеризация

Благодарности: Работа выполнена при поддержке гранта РФ (№ 23-21-00259).

Для цитирования: Кочегурова Е.А., Сайберт С.М., Татьянакина К.В. Оптимизация параметров гибридного алгоритма прогнозирования с использованием ансамбля моделей в режиме реального времени // Известия Томского политехнического университета. Промышленная кибернетика. – 2024. – Т. 2. – № 4. – С. 26–33.
DOI: 10.18799/29495407/2024/4/76

UDC 519.6+681.51
DOI: 10.18799/29495407/2024/4/76

Optimization of hybrid-forecasting algorithm parameters using a model ensemble in real time

E.A. Kochegurova[✉], С.М. Saybert, K.V. Tatyankina

¹National Research Tomsk Polytechnic University, Tomsk, Russian Federation

[✉]kochev@tpu.ru

Abstract. Aim. To develop ensemble or multi-modeling technologies for optimization of forecasting model parameters. The proposed forecasting model in the form of a recurrent penalty spline (P-spline) has several adjustable parameters, which ensures the adaptability of the model for predicting the behavior of a time series based on its retrospective values. Creating an ensemble of models in the class of variable P-spline parameters is the initial information for longitudinal clustering of time series. Such an approach allows us to estimate the centers of clusters along the time axis, which correspond to the optimal values of the model parameters on the selected time series segment in real time. This made it possible to increase the efficiency of the recurrent P-spline as a real-time forecasting model, reduce computational costs and increase the performance of forecasting algorithms.

Keywords: real-time forecasting, penalized P-spline, ensemble modeling, performance metrics, density clustering

Acknowledgements: This work was supported by RSF (Project No. 23-21-00259).

For citation: Kochegurova E.A., Saybert S.M., Tatyankina K.V. Optimization of hybrid-forecasting algorithm parameters using a model ensemble in real time. *Bulletin of the Tomsk Polytechnic University. Industrial Cybernetics*, 2024, vol. 2, no. 4, pp. 26–33. DOI: 10.18799/29495407/2024/4/76

Введение

Анализ задач прогнозирования показал [1], что краткосрочное прогнозирование имеет большое значение для предсказания чрезвычайных ситуаций как техногенного, так и природного характера. Оно актуально в разных сферах жизни и позволяет принимать более эффективные решения на основе предсказаний будущих событий и явлений.

Особую актуальность имеет прогнозирование в реальном масштабе времени (РМВ). Повышение эффективности прогнозирования в РМВ обусловлено достижением противоречивых показателей: повышение точности и уменьшение запаздывания результата прогноза.

В последние годы возрос интерес научного и инженерного сообщества к нелинейным и адаптивным моделям, а также к прикладным задачам на их основе. Обоснован подобный интерес нелинейной природой многих процессов реальной жизни.

Природу нестационарных и быстроменяющихся процессов более адекватно отражают нелинейные модели. Нелинейные адаптивные модели и фильтры обладают хорошей гибкостью и высокой производительностью [2, 3]. Нелинейность моделей отражает нестационарную природу процессов, а адаптивность моделей повышает эффективность их применения. Вычислительные затраты определяются главным образом принципами адаптации и обучения модели.

Структура модели определяет её тип. Существует множество различных структур моделей, которые отличаются архитектурой, типом и другими классификационными признаками.

К модельным функциям предъявляется ряд требований в зависимости от типа прикладной задачи: выделение тренда, дифференцирование, прогноз и др. В задачах интерпретации данных целесообразно использовать модельные функции на основе простого математического базиса. Наличие математического базиса упрощает дальнейшее использование модели в прикладных задачах и повышает интерпретируемость данных. Так, сплайн-функции довольно эффективны в прикладных задачах интерпретации благодаря их способности одновременно адаптироваться и к данным временного ряда (ВР), и к требуемой гладкости.

Однако при значительном количестве измерений (размере ВР) алгоритмы, основанные на сглаживающих сплайнах, требуют больших вычислительных

ресурсов [4, 5]. Это обстоятельство ограничивает применение сглаживающих сплайн-функций в режиме реального времени. Принципиально локальное описание процессов допускают базисные В-сплайны и штрафные Р-сплайны. В первом случае эффективность модели полностью определяется оптимальным выбором узлов [6, 7]. Р-сплайны нередко совмещают узлы и отсчеты, что приводит к избыточной вычислительной сложности [8–11]. Для снижения вычислительной сложности возможно объединение входных данных в группы с постоянными параметрами Р-сплайна внутри группы.

Расчетные формулы рекуррентного штрафного сплайна

Подлежащий параметрической оптимизации Р-сплайн реализован на основе вариационного подхода. Но не для всего интервала наблюдения, а отдельно для каждого звена сплайна. А вместо постоянного сглаживающего параметра для данных всего ВР производится его адаптация к данным ВР на каждом звене сплайна. Дополнительно объединение данных в блок решает проблему выбора узлов сплайна.

Получение классического штрафного сплайна $S(t)$ по отсчетам $y(t_i)$, $i = \overline{1, n}$ основано на оптимизации специального вида функционала [12], определенного на всем интервале наблюдения $[a, b]$:

$$J(S) = \lambda \cdot \int_a^b [S''(t)]^2 dt + \sum_{i=0}^n [S(t_i) - y(t_i)]^2, \quad (1)$$

где первое слагаемое вместе со сглаживающим параметром определяет штраф кривизны; второе слагаемое реализует обычный метод наименьших квадратов.

Для реализации режима реального времени функционал (1) модифицирован нами и определен для каждого i -го звена сплайна на основании входных данных, собранных в группы по h измерений между отсчетами t_0^i, t_h^i с шагом дискретизации Δt :

$$J(S) = (1 - \rho)(h\Delta t)^2 \int_{t_0^i}^{t_h^i} [S''(t)]^2 dt + \rho \sum_{j=0}^h [S(t_j^i) - y(t_j^i)]^2. \quad (2)$$

В (2) введен сглаживающий множитель ρ , нормированный для каждого звена сплайна. Это сужает диапазон выбора $\rho \in [0, 1]$ и придает сглаживающему параметру физический смысл.

Для реализации штрафного сплайна для i -го звена в реальном времени:

$$S_i(\tau) = a_0^i + a_1^i \cdot \tau + a_2^i \cdot \tau^2 + a_3^i \cdot \tau^3, \quad -q \leq \tau \leq h - q. \quad (3)$$

В работе [13] были получены формулы для коэффициентов кубического сплайна в рекуррентном виде.

При переходе от формул (2) к (3) сплайн $S(t_i^j)$ заменен $S_i(\tau)$ для i -го звена. Таким образом, основными параметрами сплайна (3) являются: $\rho \in [0, 1]$, h , q , τ .

Сопряжение звеньев сплайна означает равенство сплайна и его непрерывных производных для $(i-1)$ -го и i -го звеньев в момент t_q^i , $q = \overline{0, h-1}$. То есть $S^{(k)}(t_{q+1}^{i-1})_+ = S^{(k)}(t_q^i)_-$. Число непрерывных производных зависит от дефекта сплайна. Для дефекта $2-k=0, 1$, т. е. сопряжен сам сплайн и первая производная. А для дефекта $1-k=0$ сопряжен только сплайн. Далее в работе анализируется только сплайн дефекта 2. Для этого случая разрывные коэффициенты a_2^i , a_3^i найдены из условия минимизации функционала (2)

$$\begin{aligned} \frac{\partial J(S)}{\partial a_2^i} = 0, \quad \frac{\partial J(S)}{\partial a_3^i} = 0. \\ a_0^i = a_0^{i-1} + a_1^{i-1} + a_2^{i-1} + a_3^{i-1}; \\ a_1^i = a_1^{i-1} + 2a_2^{i-1} + 3a_3^{i-1}; \\ a_2^i = \frac{\rho(F_1^i C - F_2^i A)}{BC - A^2}; \\ a_3^i = \frac{\rho(F_2^i B - F_1^i A)}{BC - A^2}; \\ A = 6(1 - \rho)h^4 + \rho H_5; \\ B = 4(1 - \rho)h^3 + \rho H_4; \\ C = 12(1 - \rho)h^5 + \rho H_6; \\ F_1^i = \sum_{j=0}^h y(t_j^i) j^2 - a_0^i H_2 - a_1^i H_3; \\ F_2^i = \sum_{j=0}^h y(t_j^i) j^3 - a_0^i H_3 - a_1^i H_4; \\ H_n = \sum_{j=0}^h j^n, \quad n = \overline{2, 6}. \end{aligned} \quad (4)$$

Таким образом, формулы (3), (4) определяют рекуррентную схему расчета Р-сплайна. Рекуррентность определяется способом вычисления коэффициентов a_0^i , a_1^i . При этом сплайн является локальным по отношению к группе измерений, включающей h отсчетов ВР. В целом формулы (3), (4) представляют собой набор алгебраических выражений и не требуют дополнительно численных методов.

Поэтому вычислительные схемы штрафного сплайна оказались довольно экономичными с позиции и быстродействия, и памяти. Это определило возможность их использования в задачах интерпретации и экстраполяции измерительной информации в РМВ.

Анализ параметров штрафного сплайна

Штрафной Р-сплайн, реализованный формулами (3), (4) для i -го звена сплайна, содержит четыре параметра, подлежащие оптимизации:

- $\rho \in [0, 1]$ – сглаживающий множитель;
- h – длина звена сплайна, или число отсчетов временного ряда (ВР) внутри звена;
- q – номер отсчета t_q^i внутри i -го звена для сопряжения $(i-1)$ -го и i -го звеньев;
- τ – момент вычисления сплайна t_τ^i внутри i -го звена. Его значение определяет задержку прогнозирования.

Параметры сплайна оказывают разное влияние на сглаживающие и предсказательные свойства Р-сплайна и могут быть объединены в два класса:

- параметры топологии;
- параметры сглаживания.

В соответствии с классами параметров Р-сплайна можно выделить две задачи: структурной и параметрической оптимизации.

Отличительная особенность предлагаемого Р-сплайна (4) – это возможность сопряжения смежных звеньев в любой точке $q=t_k^i$ внутри i -го звена ($k = \overline{0, h}$) (рис. 1, а). Это особенность уникальна и для теории сплайнов с последовательным сопряжением звеньев, и для реализации в реальном времени со скользящим окном.

Временные моменты сопряжения сплайна q и вычисления τ являются параметрами вычислительных схем Р-сплайна. И на основе их взаимного расположения разработаны несколько топологий для вычислительных схем сплайна [14], в том числе последовательной рис. 1, б и многократной фильтрации рис. 1, в. И все три схемы сочетают рекуррентность коэффициентов сплайна и локальность к группе отсчетов внутри звена.

Наибольший интерес с позиции РМВ имеет универсальная вычислительная схема, представленная на рис. 1, а. И именно параметры q и τ , как параметры топологии, определяют структурную адаптацию Р-САФ. Параметры структурной оптимизации в большей степени определяются особенностями прикладной задачи и режимом реального времени.

Сглаживающие свойства Р-сплайна определяются параметрами самого сплайна h и ρ . Эти параметры и задают адаптивные свойства Р-САФ, т. е. участвуют в процессе параметрической адаптации.

Ранее проведено исследование влияния параметров h и ρ на свойства сплайна с позиции цифрового фильтра [14].




Рис. 1. Топология вычислительных схем Р-САФ: а) смешанная; б) последовательная; в) параллельная
Fig. 1. Topology of R-SAF: a) mixed circuit; b) sequential circuit; c) parallel circuit

Было установлено, что ширина аппаратной функции фильтра уменьшается и с ростом сглаживающего множителя ρ , и с ростом длины сплайна h . С увеличением числа отсчетов звена h полоса пропускания фильтра уменьшается. Соответственно уменьшается и ширина аппаратной функции, что видно из рис. 2. Гладкость сплайна на выходе фильтра в таких случаях увеличивается, однако он отдален от линии регрессии, что приводит к увеличению систематической ошибки. Таким образом, ширина аппаратной функции физически интерпретируется как фактор, влияющий на точность экстраполяции.




Рис. 2. Аппаратная функция Р-сплайна
Fig. 2. Hardware function of P-spline

Влияние сглаживающего множителя ρ много слабее, чем параметра h . И при $h > 15$ влияние параметра сглаживания практически нет. Однако в задачах реального времени быстродействие алгоритма Θ является главным фактором при ограничении на погрешность аппроксимации $\Phi[S(t) - y(t)]$. При этом допустимое для РМВ значение параметра $h \in [3, 10]$.

Поэтому параметр ρ оказывает существенное влияние на качество экстраполяции и подлежит оптимизации.

Оптимизация параметров на основе ансамблевого моделирования

В зависимости от способа создания ансамбля, агрегирования и декомпозиции его элементов можно выделить несколько основных задач моделирования [15, 16]:

- мульти моделирование на основе разных показателей процесса;
- мульти моделирование на основе одного показателя, но разных типов моделей;
- модели ансамблевого машинного обучения;
- покрытие пространства, или явное задание параметров модели и др.

Ансамблевое или мульти моделирование – довольно современная идея, предлагаемая в работе как инструмент для адаптации параметров модели прогнозирования на основе штрафного сплайна.

Ранее проведенные исследования эволюционных алгоритмов оптимизации (генетические и иммунные) в задаче оптимизации параметров модели показали неплохую точность прогнозирования, но низкое быстродействие алгоритмов, что не допустимо в задачах реального времени [17].

Используемое здесь ансамблевое параметрическое моделирование можно рассматривать как альтернативную оптимизацию. Ряд авторов предложили применить идею ансамблевого моделирования относительно коэффициентов сплайна в апостериорном режиме оценивания, когда ВР представлен полностью [18].

Этот подход действительно снижает размерность ансамбля моделей по сравнению с ансамблями ВР. Однако покрытие пространства параметров (коэффициентов сплайна) довольно проблематично ввиду отсутствия их диапазона. В РМВ этот подход также невозможен.

Для реализуемого в этом проекте штрафного P-сплайна основные параметры ограничены диапазонами на этапе модификации экстремального функционала Тихонова (1), (2). Сглаживающий множитель нормирован в диапазоне [0,1], а размер сегмента (группа измерений) ограничен сверху допустимым запаздыванием прогноза. Поэтому создание ансамбля моделей P-сплайна относительно параметров модели представляется обоснованным математическим аппаратом быстрой адаптации с реализацией в РМВ [19, 20].

Ансамбль моделей на основе штрафного сплайна

Создание мульти моделей на основе штрафного сплайна основано на варьировании сглаживающего параметра ρ в диапазоне его изменения [0,1]. При этом возможны две стратегии.

1. Параметр ρ принимает фиксированные значения в диапазоне его изменения с некоторым шагом, например 0,1. Тогда мульти модель включает 10 моделей на основе кубического сплайна со значениями ρ от 0,1 до 1 с шагом 0,1.

Следующий этап в адаптации – кластеризация на основе средних значений (k-means). При этом усредняются значения предсказания, а не сглаживающего параметра ρ . В результате полученные центры кластеров указывают итоговое значение экстраполяции, как показано на рис. 3.

2. Случайное мульти моделирование. Предлагается построение n моделей, в которых параметры P-сплайна h и ρ выбираются случайным образом. В этом случае задаются значения n , а также диапазоны параметров $h \in [3, 10]$ и $\rho \in [0, 1]$.




Рис. 3. Ансамблевое моделирование и кластеризация на основе P-сплайна

Fig. 3. Ensemble modeling and clustering based on P-spline

Для оценки эффективности предсказания используются наиболее популярные показатели точности в абсолютном и процентном представлении:

- MAE – средняя абсолютная ошибка

$$MAE = \frac{1}{n} \sum_{i=1}^n |S_i - y_i|; \quad (5)$$

- MAPE – средняя абсолютная процентная ошибка

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{S_i - y_i}{y_i} \right|; \quad (6)$$

- MSE – средняя квадратичная ошибка

$$MSE = \frac{1}{n} \sum_{i=1}^n (S_i - y_i)^2; \quad (7)$$

- MSPE – средняя квадратичная процентная ошибка

$$MSPE = \frac{100}{y_{\max} - y_{\min}} \sum_{i=1}^n \left(\frac{S_i - y_i}{y_i} \right)^2. \quad (8)$$

Процентные показатели точности не зависят от диапазона и шкалы исследуемого процесса и, соответственно, более наглядны.

В качестве реального ВР были использованы данные фондового рынка. ВР содержит 105986 ежедневных значений цен различных акций в разные периоды времени. Данные взяты с платформы Kaggle.com, пример временного ряда представлен на рис. 4.




Рис. 4. Изменение цены акций Google в период с 19.08.2003 по 24.03.2022

Fig. 4. Change in Google stock price from 19.08.2003 to 24.03.2022

Для сравнения прогностических свойств разных моделей были использованы также другие классические модели из различных классов [21]:

- линейные статистические – авторегрессионная модель AR;

- экспоненциальное сглаживание Хольта–Винтерса;
- регрессионная модель Ridge;
- модель машинного обучения Decision Tree;
- модель на основе алгоритма классификации KNN.

Таблица. Показатели эффективности прогноза

Table. Forecast performance indicators

Модель/Model	MSPE	MAPE	MSE	MAE
Кубический сплайн ($\rho=0,2$)/Cubic spline ($\rho=0,2$)	2,14	53,86	99118,87	2,80
Кубический сплайн ($\rho=0,8$)/Cubic spline ($\rho=0,8$)	1,74	44,18	67126,94 2	2,23
Случайный ансамбль сплайнов ($n=30, m_{\max}=10$) Random spline ensemble ($n=30, m_{\max}=10$)	1,72	41,88	62356,32	2,23
Ансамбль сплайнов Ensemble of splines	1,73	43,61	66739,57	2,22
AR	1,46	36,36	47463,88	1,89
Holt–Winters ES	1,55	39,03	54203,88	1,95
Ridge	2,62	36,27	41337,45	1,77
Decision Tree	2,27	54,08	107469,5 1	2,77
KNN	1,98	47,59	77182,92	2,35

Предсказания для всех моделей даются на основе предыдущих 10 значений ВР, за исключением случайного ансамбля сплайнов, в котором шаг

выбирается случайно, но не превышает 10. Результаты прогноза в виде показателей качества (5)–(8) представлены в таблице.

Анализ результатов исследования

Сравнительный анализ предложенного алгоритма прогнозирования на основе Р-сплайна с другими известными моделями позволил сделать следующие выводы:

- лучшие результаты для прогнозирования цен акций получены для статистических моделей AR и Holt–Winters. MSPE=1,46 % и MSPE=1,55 % соответственно;
- алгоритмы на основе ансамбля Р-сплайна показали следующий за статистическими моделями результат MSPE=(1,72–1,73) %;
- адаптация параметров Р-сплайна на основе ансамблевых моделей возможна в качестве инструмента оптимизации параметров модели прогнозирования в РМВ.

В заключение следует отметить, что показатели точности ансамблевых моделей прогнозирования на основе Р-сплайна незначительно отличаются от показателей классических моделей прогнозирования. Однако среди исследованных здесь алгоритмов только ансамблевые модели допускают реализацию в РМВ, показатели эффективности которых лишь асимптотически приближаются к оценкам апостериорных алгоритмов.

СПИСОК ЛИТЕРАТУРЫ

1. Jaseena K.U., Kovoov B.C. Deterministic weather forecasting models based on intelligent predictors: A survey // Journal of King Saud University – Computer and Information Sciences. – 2022. – Vol. 34. – P. 3393–3412.
2. Haykin S.S. Adaptive filter theory. 5th ed. – London: Pearson Education, 2014. – 912 p.
3. Comminiello D., Principe J.C. Adaptive learning methods for nonlinear system modeling. – Oxford: Butterworth-Heinemann, 2018. – 388 p.
4. Extending fundamental formulas from classical B-splines to quantum B-splines / G. Budakci, Ç. Dişbüyük, R.N. Goldman, H. Oruç // Journal of Computational and Applied Mathematics. – 2015. – № 282. – P. 17–33. DOI: 10.1016/j.cam.2014.12.034
5. Wang Y. Smoothing splines: methods and applications. – Boca Raton: CRC Press, 2011. – 384 p.
6. Sharif S., Kamal S. Comparison of significant approaches of penalized spline regression (P-splines) // Pakistan Journal of Statistics and Operation Research. – 2018. – Vol. 14. – № 2. – P. 289–303. DOI: <https://doi.org/10.18187/pjsor.v14i2.1948>
7. Customizable adaptive regularization techniques for B-spline modeling / D. Lenz, R. Yeh, V. Mahadevan, I. Grindeanu, T. Peterka // Journal of Computational Science. – 2023. – Vol. 71. – Article number 102037.
8. Yang L., Hong Y. Adaptive penalized splines for data smoothing // Computational Statistics and Data Analysis. – 2017. – Vol. 108. – P. 70–83.
9. Krivobokova T., Crainiceanu C.M., Kauermann G. Fast adaptive penalized splines // Journal of Computational and Graphical Statistics. – 2008. – Vol. 17 (1). – P. 1–20.
10. S-estimation for penalized regression splines / K. Tharmaratnam, G. Claeskens, C. Croux., M. Salibián-Barrera // Journal of Computational and Graphical Statistics. – 2010. – Vol. 19 (3). – P. 609–625.
11. Kochegurova E.A., Gorokhova E.S. Current derivative estimation of non-stationary processes based on metrical information // Lecture Notes in Computer Science. – 2015. – Vol. 9330. – P. 512–519. DOI: http://dx.doi.org/10.1007/978-3-319-24306-1_50
12. Kochegurova E.A., Gorokhova E.S. Current estimation of the derivative of a nonstationary process based on a recurrent smoothing spline // Optoelectronics, Instrumentation and Data Processing. – 2016. – Vol. 52. – Iss. 3. – P. 280–285.
13. Кочегурова Е.А., Кочегуров А.И. Рожкова Н.Е. Частотный анализ рекуррентных вариационных Р-сплайнов // Автометрия. – 2017. – Т. 53. – № 6. – С. 67–75.
14. Kochegurova E.A., Wu D. Realization of a recursive digital filter based on penalized splines // Computer Optics. – 2018. – Vol. 42 (6). – P. 1083–1092.
15. Ковальчук С.В. Интеллектуальные технологии создания, исследования и применения композитных моделей сложных систем: дисс. ... д-ра техн. наук. – СПб., 2018. – 270 с.
16. Wang F. Forecasting the electronic waste quantity with a decomposition-ensemble approach // Waste Management. – 2021. – Vol. 120. – P. 828–838.

17. Kochegurova E.A., Repina E.Y., Tsekhan O.B. Гибридный подход для краткосрочного прогнозирования временных рядов на основе штрафного P-сплайна и эволюционной оптимизации // Компьютерная оптика. – 2020. – Т. 44. – № 5. – С. 821–829.
18. A P-spline based clustering approach for portfolio selection / C. Iorio, G. Frasso, A. D'Ambrosio, R. Siciliano // Expert Systems with Applications. – 2018. – Vol. 95 (1). – P. 88–103.
19. Budgaga W. Predictive analytics using statistical, learning, and ensemble methods to support real-time exploration of discrete event simulations // Future Generation Computer Systems. – 2016. – Vol. 56. – P. 360–374.
20. Bhusal N. Deep ensemble learning-based approach to real-time power system state estimation // International Journal of Electrical Power & Energy Systems. – 2021. – Vol. 129. – Article number 106806.
21. Shah D., Thaker M. A review of time series forecasting methods // International journal of research and analytical reviews. – 2024. – Vol. 11. – P. 749–755.

Информация об авторах

Елена Алексеевна Кочегурова, кандидат технических наук, доцент отделения информационных технологий Инженерной школы информационных технологий и робототехники, Национальный исследовательский Томский политехнический университет, Россия, 634050, г. Томск, пр. Ленина, 30; kocheg@tpu.ru; <https://orcid.org/0000-0003-4473-528X>

Софья Михайловна Сайберт, студент направления Информатика и вычислительная техника Инженерной школы информационных технологий и робототехники, Национальный исследовательский Томский политехнический университет, Россия, 634050, г. Томск, пр. Ленина, 30; sms25@tpu.ru

Ксения Витальевна Татьянкина, студент направления Информационные технологии Инженерной школы информационных технологий и робототехники, Национальный исследовательский Томский политехнический университет, Россия, 634050, г. Томск, пр. Ленина, 30; kvt23@tpu.ru

Поступила: 20.10.2024

Принята: 25.11.2024

Опубликована: 28.12.2024

REFERENCES

1. Jaseena K.U., Kovoov B.C. Deterministic weather forecasting models based on intelligent predictors: A survey. *Journal of King Saud University – Computer and Information Sciences*, 2022, vol. 34, pp. 3393–3412.
2. Haykin S.S. *Adaptive filter theory*. 5th ed. London, Pearson Education, 2014. 912 p.
3. Comminiello D., Principe J.C. *Adaptive learning methods for nonlinear system modeling*. Oxford, Butterworth-Heinemann, 2018. 388 p.
4. Budakci G., Dişibüyük Ç., Goldman R.N., Oruç H. Extending fundamental formulas from classical B-splines to quantum B-splines. *Journal of Computational and Applied Mathematics*, 2015, no. 282, pp. 17–33. DOI: 10.1016/j.cam.2014.12.034
5. Wang Y. *Smoothing splines: methods and applications*. Boca Raton, CRC Press, 2011. 384 p.
6. Sharif S., Kamal S. Comparison of significant approaches of penalized spline regression (P-splines). *Pakistan Journal of Statistics and Operation Research*, 2018, vol. 14, no. 2, pp. 289–303. DOI: <https://doi.org/10.18187/pjsor.v14i2.1948>
7. Lenz D., Yeh R., Mahadevan V., Grindeanu I., Peterka T. Customizable adaptive regularization techniques for B-spline modeling. *Journal of Computational Science*, 2023, vol. 71, article number 102037.
8. Yang L., Hong Y. Adaptive penalized splines for data smoothing. *Computational Statistics and Data Analysis*, 2017, vol. 108, pp. 70–83.
9. Krivobokova T., Crainiceanu C.M., Kauermann G. Fast adaptive penalized splines. *Journal of Computational and Graphical Statistics*, 2008, vol. 17 (1), pp. 1–20.
10. Tharmaratnam K., Claeskens G., Croux C., Salibián-Barrera M. S-estimation for penalized regression splines. *Journal of Computational and Graphical Statistics*, 2010, vol. 19 (3), pp. 609–625.
11. Kochegurova E.A., Gorokhova E.S. Current derivative estimation of non-stationary processes based on metrical information. *Lecture Notes in Computer Science*, 2015, vol. 9330, pp. 512–519. DOI: http://dx.doi.org/10.1007/978-3-319-24306-1_50
12. Kochegurova E.A., Gorokhova E.S. Current estimation of the derivative of a nonstationary process based on a recurrent smoothing spline. *Optoelectronics, Instrumentation and Data Processing*, 2016, vol. 52, Iss. 3, pp. 280–285.
13. Kochegurova E.A., Kochegurov A.I., Rozhkova N.E. Frequency analysis of recurrent variational P-splines. *Avtometriya*, 2017, vol. 53, no. 6, pp. 67–75. (In Russ.)
14. Kochegurova E.A., Wu D. Realization of a recursive digital filter based on penalized splines. *Computer Optics*, 2018, vol. 42 (6), pp. 1083–1092.
15. Kovalchuk S.V. *Intelligent technologies for the creation, research and application of composite models of complex systems*. Dr. Diss. St. Petersburg, 2018. 270 p. (In Russ.)
16. Wang F. Forecasting the electronic waste quantity with a decomposition-ensemble approach. *Waste Management*, 2021, vol. 120, pp. 828–838.
17. Kochegurova E.A., Repina E.Y., Tsekhan O.B. Hybrid approach for time series forecasting based on a penalty p-spline and evolutionary optimization. *Computer Optics*, 2020, vol. 44, no. 5, pp. 821–829. (In Russ.) DOI: 10.18287/2412-6179-CO-667
18. Iorio C., Frasso G., D'Ambrosio A., Siciliano R. A P-spline based clustering approach for portfolio selection. *Expert Systems with Applications*, 2018, vol. 95 (1), pp. 88–103.

19. Budgaga W. Predictive analytics using statistical, learning, and ensemble methods to support real-time exploration of discrete event simulations. *Future Generation Computer Systems*, 2016, vol. 56, pp. 360–374.
20. Bhusal N. Deep ensemble learning-based approach to real-time power system state estimation. *International Journal of Electrical Power & Energy Systems*, 2021, vol. 129, article number 106806.
21. Shah D., Thaker M. A Review of time series forecasting methods. *International journal of research and analytical reviews*, 2024, vol. 11, pp. 749–755.

Information about the authors

Elena A. Kochegurova, Cand. Sc., Associate Professor, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation; kaicc@tpu.ru; <https://orcid.org/0000-0003-4473-528X>

Sofia M. Saybert, student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation; sms25@tpu.ru

Ksenia V. Tatyankina, student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation; kvt23@tpu.ru

Received: 20.10.2024

Revised: 25.11.2024

Accepted: 28.12.2024