



Серия «Математика»

2018. Т. 26. С. 76–90

Онлайн-доступ к журналу:

<http://mathizv.isu.ru>

ИЗВЕСТИЯ

Иркутского
государственного
университета

УДК 51-74

MSC 45D05, 68T05

DOI <https://doi.org/10.26516/1997-7670.2018.26.76>

Интегральные модели для управления накопителями энергии на основе прогноза нагрузки в ЭЭС с возобновляемыми источниками генерации*

Д. Н. Сидоров

*Институт систем энергетики им. Л. А. Мелентьева СО РАН, Иркутск,
Российская Федерация;*

*Иркутский национальный исследовательский технический университет,
Иркутск, Российская Федерация;*

Иркутский государственный университет, Иркутск, Российская Федерация

А. В. Жуков

Институт солнечно-земной физики СО РАН, Иркутск, Российская Федерация;

*Институт систем энергетики им. Л. А. Мелентьева СО РАН, Иркутск,
Российская Федерация*

И. Р. Муфтахов

*Иркутский информационно-вычислительный центр ОАО «РЖД», Иркутск,
Российская Федерация;*

*Институт систем энергетики им. Л. А. Мелентьева СО РАН, Иркутск,
Российская Федерация*

Аннотация. Широкое использование возобновляемых источников энергии в условиях свободного рынка электроэнергии приводит к необходимости создания новых средств поддержания баланса между генерацией и потреблением электроэнергии, в частности управления накопителями энергии в современных электроэнергетических системах (ЭЭС). Однако большинство предлагаемых моделей накопителей энергии не учитывают некоторые важные параметры, такие как нелинейная зависимость коэффициентов полезного действия (КПД) от срока службы и изменения мощности работы накопителей, распределение во времени нагрузки между несколькими независимыми накопителями и другие. Для решения этой проблемы в данной работе предложены модели на основе интегральных уравнений Вольтерра первого рода с

* Работа выполнена при финансовой поддержке РФФИ в рамках научного проекта № 18-31-00206.

ядрами, представленными в виде разрывных функций. Такие модели позволяют определить неизвестную знакпеременную функцию изменения мощности накопителей при известных значениях нагрузки потребителей и генерации. Однако для эффективного решения этой задачи требуется качественный прогноз электрической нагрузки, поэтому в статье предлагается несколько прогнозных моделей на основе машинного обучения. В качестве входных переменных такие модели используют среднесуточную температуру, значения нагрузки со смещением по времени, скользящие средние и другие признаки. В статье приведено сравнение результатов прогнозирования для нескольких моделей: случайный лес, градиентный бустинг над решающими деревьями, метод опорных векторов, а также мультипараметрическая линейная регрессия. Эффективность предложенных моделей продемонстрирована на реальных данных энергосистемы Германии.

Ключевые слова: уравнение Вольтерра первого рода, машинное обучение, прогнозирование, электроэнергетические системы, накопители энергии.

1. Существующие модели накопителей и прогноза электрической нагрузки

В настоящее время энергетика находится на пороге новых изменений вследствие широкого использования различных возобновляемых источников энергии в условиях свободного рынка электроэнергии. Высокая доля различных возобновляемых источников энергии увеличивает изменчивость и непостоянность выработки электроэнергии, нарушая оптимальный режим работы традиционных энергосистем. В этих условиях большой интерес вызывают исследования, связанные с использованием накопителей энергии, таких как гидроаккумулирующие электростанции [18], аккумуляторы на сжатом воздухе [12], аккумуляторные батареи [8] и другие [4; 16; 19].

Также проводятся исследования по моделированию и оптимизации хранения электрической энергии на примере экспериментальных или реальных энергосистем [6; 14]. Среди отечественных исследователей много работ по накопителям энергии проводили Н. В. Гулия, Д. А. Бут, Д. Н. Карамов [2], а среди зарубежных можно отметить О. Tremblay, L.-A. Dessaint и Dirk Uwe Sauer. В исследованиях Rodolfo Dufo-Lopez, Jose L. Bernal-Agustin, D. Tsuanayo, E. Dursun [7;9;23] используется метод хронологического моделирования работы электрохимических накопителей энергии с определением состояния заряда, напряжения, сопротивления, токов заряда и разряда относительно каждого шага расчетного периода с соблюдением эксплуатационно-технических ограничений.

Данные исследования способствуют лучшему пониманию текущего состояния исследований энергосистем с использованием накопителей электроэнергии, их технические характеристики, функциональные ограничения и возможности проектирования систем с использованием возобновляемых источников энергии. Достаточно большое внимание

уделяется анализу производительности, техническим характеристикам и стоимости использования батарей. К сожалению, нужно отметить, что большинство работ предполагают использование констант в качестве определения КПД используемых накопителей энергии, что при моделировании работы накопителей определяет использование линейных моделей. Данный подход не позволяет учитывать нелинейные процессы сокращения располагаемой емкости накопителя энергии с течением времени. Поэтому в данной статье предлагается модель накопителя на основе интегральных уравнений Вольтерра, которые могут учитывать такие характеристики работы накопителей, как емкость, КПД, количество циклов и скорость разрядки/зарядки, распределения нагрузки между несколькими накопителями. Входным параметром интегральной модели является прогноз электрической нагрузки - один из ключевых факторов эффективной работы накопителя. Поэтому авторами предлагаются модели прогнозирования нагрузки, построенные с помощью методов машинного обучения.

Ошибки прогнозирования снижают качество управления как накопителями, так и ЭЭС в целом: заниженный прогноз приводит к необходимости использования дорогостоящих аварийных электростанций или покупки недостающей мощности у соседних производителей по более высоким ценам; завышенное предсказание приводит к увеличению издержек на поддержание в рабочем состоянии излишних резервных мощностей [1].

В то же время существует множество разнородных подходов к решению задачи прогнозирования, большая часть из которых опирается на традиционные методы, не рассматривая новейшие достижения в области машинного обучения и анализа данных. Поэтому авторами предложен подход, основанный на техниках анализа данных и использующий такие способы машинного обучения, как случайный лес [5] (Random Forest, RF), градиентный бустинг над решающими деревьями [11] (Gradient Boosting, GB), регрессия методом опорных векторов [10] (Support Vector Machine, SVM).

Одним из важнейших вопросов, кроме выбора прогнозной модели, является выявление формальных факторов, влияющих на прогноз. Их можно условно поделить на социально-экономические и метеорологические, которые в свою очередь могут иметь циклический (например, день недели), естественный (отражающие естественную активность технологической или природной среды, например продолжительность отопительного сезона или значение атмосферного давления) или случайный характер (аварии или резкие изменения погодных условий) [3].

Все эти факторы являются исходной информацией для прогноза. И для её представления в наиболее удобном для модели виде используются такие преобразования, как метод главных компонент или преобразование Гильберта – Хуанга.

По типу применяемых математических методов прогнозирования подходы к решению задачи могут быть разделены на следующие категории: 1) на основе традиционных статистических и вероятностных методов анализа временных рядов; 2) с использованием методов искусственного интеллекта (так называемые интеллектуальные методы).

К первой категории относятся традиционные статистические методы анализа временных рядов, такие как мультипараметрическая регрессия (далее *linear model*, LM), экспоненциальное сглаживание, модели авторегрессии, скользящего среднего и их модификации, такие как ARMA, ARIMA и т. д. Такие модели хорошо показывают себя в случае, если входные признаки не коррелируют друг с другом, а их зависимость от целевой переменной имеет линейный характер. Поэтому зачастую они не могут дать достаточно точный прогноз для данных со сложными зависимостями нагрузки от метеорологических и социально-экономических факторов. К тому же без дополнительной фильтрации такие методы неустойчивы по отношению к выбросам и ошибкам в данных. К методам вероятностного прогнозирования принадлежат метод статистического градиента, критерия Байеса, фильтрации, гипотез и т. д. Для того чтобы получить непрерывное прогнозирование, могут использоваться фильтры: для прогнозирования стационарных процессов фильтр Винера – Хопфа, для нестационарных процессов используется фильтр Калмана. Эти методы, как правило, применяются совместно с регрессионными в качестве предварительных фильтров, что позволяет улучшить результат прогнозирования и сделать его устойчивее к некорректным данным.

Второй подход, наиболее часто применяемый в настоящее время, использует традиционные и современные модели машинного обучения, методы оптимизации и агрегирования экспертных знаний. Среди моделей машинного обучения наиболее часто применяются как широко известные искусственные нейронные сети прямого распространения, метод опорных векторов, так и глубокие ИНС. Для решения проблем подбора их параметров используются различные методы оптимизации, такие как генетические алгоритмы. Эффективность использования методов искусственного интеллекта обусловлена не только их способностью приближать сложные зависимости, но и возможностью объединения разнородных техник в составе одной модели. Например, экспертные знания могут быть добавлены в модель в виде дополнительного признака. А методы оценки значимости переменных позволяют узнать, какие из исследуемых признаков наиболее важны как в конкретных условиях, так и для прогноза в целом.

На практике всё чаще применяются объединения представленных подходов. Более подробно с различными подходами к прогнозированию нагрузки можно ознакомиться в обзоре [13].

2. Предлагаемые модели работы накопителей

Для моделирования работы накопителей предлагается использовать следующую нелинейную интегральную модель с ограничениями

$$\left\{ \begin{array}{l} \int_0^t K(t, s, x(s)) ds = f(t), \quad 0 \leq s \leq t \leq T, \quad f(0) = 0, \\ v(t) = \int_0^t x(s) ds, \quad \max_{t \in [0, T]} v(t) \leq v_{max}, \\ E_{min}(t) \leq \int_0^t v(s) ds \leq E_{max}(t), \\ 0 < \alpha_1(t) < \alpha_2(t) < \dots < \alpha_{n-1}(t) < t, \end{array} \right. \quad (2.1)$$

где ядро представлено функцией

$$K(t, s, x(s)) = \begin{cases} K_1(t, s)G_1(s, x(s)), & t, s \in m_1, \\ \dots & \dots \\ K_n(t, s)G_n(s, x(s)), & t, s \in m_n \end{cases} \quad (2.2)$$

при ограничениях

- $m_i = \{t, s \mid \alpha_{i-1}(t) < s < \alpha_i(t)\}$;
- $\alpha_0(t) = 0, \alpha_n(t) = t, i = \overline{1, n}$;
- $\alpha_i(t), f(t) \in C^1_{[0, T]}$, $K_i(t, s)$ имеют непрерывные производные по t для $t, s \in \overline{m_i}$;
- $K_n(t, t) \neq 0, K_i(t, s), G_i(s, x(s))$ являются непрерывными;
- $\alpha_i(0) = 0, 0 < \alpha_1(t) < \alpha_2(t) < \dots < \alpha_{n-1}(t) < t$;
- $\alpha_1(t), \dots, \alpha_{n-1}(t)$ возрастают в малой окрестности $0 \leq t \leq \tau$;
- $0 < \alpha'_1(0) \leq \dots \leq \alpha'_{n-1}(0) < 1$.

Теория таких интегральных моделей с кусочно-непрерывными ядрами впервые предложена в [20] и развита в работе [21].

Здесь $f(t)$ – дисбаланс нагрузки

$$f(t) = f_{RES}(t) + f_{gen} - f_{load}(t), \quad (2.3)$$

где $f_{gen}(t)$ – генерация традиционных источников энергии, f_{RES} – генерация ВИЭ и $f_{load}(t)$ – прогнозируемая нагрузка потребителей.

Функции $\alpha_i(t)$ показывают распределение нагрузки между n накопителями, а $K_i(t, s)G_i(s, x(s))$ – КПД каждого накопителя, изменяющиеся под влиянием двух факторов – срока эксплуатации $K_i(t, s)$ и интенсивности использования в текущий момент времени $G_i(s, x(s))$, зависящей от знакопеременной функции изменения мощности $x(s)$. В данном случае предлагаемая математическая модель позволяет учесть нелинейный характер изменения КПД в зависимости от срока службы и/или поведения $x(s)$. В уравнении (2.1) знакопеременная функция изменения мощности $x(s)$ является искомой, которая позволяет при известной v_{max} (максимальной скорости работы накопителей): определить

$E(t)$ — уровень заряда накопителей при ограничениях $E_{min}(t) \leq E(t) \leq E_{max}(t)$, зависящих от типа накопителей; минимальную совокупную емкость накопителей, необходимых для покрытия дефицита нагрузки потребителей; вычислить количество циклов работы накопителей на основе чередования спадов и возрастаний функции $E(t)$; спрогнозировать срок службы накопителей.

Таким образом, проблема нахождения $x(s)$ в уравнении (2.1) является примером обратной задачи [22], для решения которой в данной работе предлагается использовать авторский численный метод из [15].

Преимуществом представленной выше нелинейной математической модели является:

- 1) Определение режимных параметров накопителей при использовании различных типов ВИЭ и накопителей.
- 2) Учёт таких характеристик работы накопителей, как мощность, скорость зарядки/разрядки, максимальное количество циклов работы, ограничение на уровень заряда.
- 3) Незначительное влияние на вычислительную сложность алгоритма при использовании большого количества типов накопителей ($n > 10$).
- 4) Учёт нелинейного характера изменения КПД.
- 5) Возможность гибко настраивать функции распределения во времени нагрузки между накопителями.

Стоит отметить, что важным фактором применения предлагаемой модели является построение качественных прогнозов генерации от ВИЭ f_{RES} и нагрузки потребителей $f_{load}(t)$. В данной работе эта задача решается с помощью построения моделей методами машинного обучения, признаки и гиперпараметры моделей рассматриваются в следующем разделе статьи.

3. Экспериментальные результаты

Для тестирования была выбрана ЭЭС Германии, так как данная ЭЭС является достаточно крупной и имеет большое число ВИЭ и накопителей электроэнергии для выравнивания суточной неоднородности графика электрической нагрузки. На данный момент на территории Германии установлено около 6,7 ГВт гидроаккумулирующих электростанций (ГАЭС) ¹.

¹ <https://www.dena.de/en/topics-projects/energy-systems/flexibility-and-storage/pumped-storage/>

Для тестирования предложенных подходов использовались общедоступные данные нагрузки энергосистемы Германии, предоставленные ENTSO-E, за период с начала 2006 по конец 2013 года. При этом нужно отметить существенный процент ВИЭ, который на 2007 год составлял 13,6 и к настоящему времени по данным статистической службы Европейского союза² вырос почти втрое. Также были использованы данные по выработке электроэнергии различных источников, расположенных в Германии³.

Однако в анализируемых данных влияние нестационарной природы ВЭУ незначительно, это было выявлено по результатам статистического теста на стационарность Дики – Фуллера. Таким образом, данный ряд может быть рассмотрен как стационарный. Однако нельзя гарантировать, что в будущем данное положение дел сохранится. И так как в этом случае нет строгих требований на время обучения моделей, то её обновление может происходить периодически путём обучения «с нуля». В случае же нестационарных данных могут быть применены онлайн-модели, такие как OzaBag [17] и PDSRF [24].

Большую часть нагрузки (47%) по данным Федеральной ассоциации энергетической и водной промышленности BDEW за 2007 год занимает промышленный сектор (в отличие от других стран с большим процентом ВЭУ, где наибольшую часть потребляет население), что может быть причиной наиболее упорядоченного характера нагрузки. На население приходится 26% нагрузки, сфера услуг занимает 25%, транспорт - 2%.

Данные нагрузки были дополнены среднесуточными температурными данными, полученными организацией European Climate Assessment & Dataset с погодной станции в Гамбурге, Мюнхене, Штуттгарте, Бохуме, а также индикатором рабочих и праздничных дней Германии. Также в качестве признаков для прогноза используются следующие показатели: текущая нагрузка, день недели, время дня, нагрузки день назад, значение нагрузки час назад, значение нагрузки неделю назад, средняя нагрузка за вчерашний день, минимальная нагрузка за вчерашний день и экспоненциальные скользящие средние с периодами 12, 24, 48, 168 часов.

Сформированный набор данных состоял из 69 713 примеров, включающий в себя данные, собранные с 2006-01-08 по 2013-12-30. Из них 60953 использовались для обучения и тестирования прогнозных моделей (при помощи блочной перекрёстной проверки), остальные 8760 — для валидации.

² <http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do>

³ <https://www.energy-charts.de/power.htm>

3.1. ПРОГНОЗИРОВАНИЕ ЭЛЕКТРИЧЕСКОЙ НАГРУЗКИ

Для прогнозирования выбрано четыре популярных модели: случайный лес, градиентный бустинг над решающими деревьями, метод опорных векторов и мультипараметрическая линейная регрессия. В результате процедуры подбора гиперпараметров были получены следующие значения: случайный лес с $mtry = 4$, бустинг $interaction.depth = 9$, $shrinkage = 0,1$, $n.minobsinnode = 10$, $sigma = 0.05515674$ и $C = 32$ для метода опорных векторов.

Как видно из таблицы 1, все рассматриваемые методы машинного обучения демонстрируют сходные ошибки. Для сравнения были выбраны три метрики: $RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (x_t - \bar{x}_t)^2}$ - среднеквадратичная ошибка, средняя абсолютная ошибка $MAE = \frac{1}{n} \sum_{t=1}^n |x_t - \bar{x}_t|$ и средняя абсолютная ошибка в процентах $MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|x_t - \bar{x}_t|}{\bar{x}_t} * 100\%$. Здесь \bar{x}_t — настоящее целевое значение, а x_t — прогнозное значение.

Таблица 1
Ошибки рассматриваемых методов.

	RMSE	MAE	MAPE,%
RF	2145.59	1262.55	2.77
GB	2144.89	1293.78	2.86
SVM	2561.60	1667.25	3.68
LM	4774.54	3735.50	8.03




Рис. 1. Среднеквадратичные ошибки прогноза для моделей машинного обучения (сверху) и мультипараметрической линейной регрессии (снизу).

Также интерес представляют ошибки по дням недели и времени суток (рис. 1). Нужно отметить, что все модели на основе машинного обучения демонстрируют сходные ошибки, наибольшие для понедельника, четверга и временного промежутка с 7 до 8 часов. Эти данные могут быть использованы для дальнейшего анализа характера нагрузки.

Необходимо также упомянуть ограничения предложенной прогнозной модели, к которым можно отнести тот факт, что она не учитывает

структуру нагрузки. Например, так как в показанном примере большую часть занимает промышленность, то, включив параметры работы крупных предприятий, можно повысить качество прогноза. Другим фактором усовершенствования модели является рассмотрение рыночной конъюнктуры как дополнительных входных параметров.

3.2. ТЕСТИРОВАНИЕ ИНТЕГРАЛЬНОЙ МОДЕЛИ НАКОПИТЕЛЕЙ ЭНЕРГИИ

Как отмечено в (2.2), в качестве КПД накопителей модель может использовать нелинейную зависимость от времени и изменения мощности работы накопителей. Сам процесс определения КПД является нетривиальной задачей, так как складывается из многих факторов, в связи с чем в данной работе в качестве тестового примера мы использовали константное значение 92%. В качестве результата работы модели (2.1) на рис. 3 показана знакопеременная функция мощности на основе фактической нагрузки и ее прогнозов (рис. 2). Положительные значения функции отражают процесс заряда накопителей, а отрицательные значения — генерацию для покрытия дисбаланса нагрузки. Можно заметить, что значение искомой функции $x(s)$ имеет зависимость от качества работы прогнозной модели.

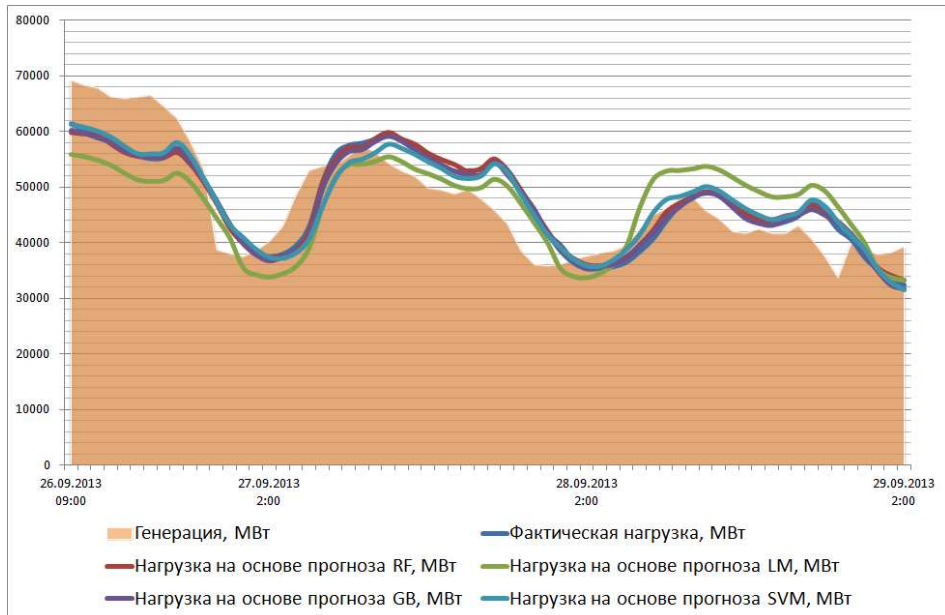


Рис. 2. Генерация и прогнозы нагрузки на данных ЭЭС Германии.

На рис.3 показана знакопеременная функция генерации накопителей (ЗФГН). Как можно видеть, даже небольшое отклонение прогноза от фактической нагрузки даёт крупные различия в работе накопителя.

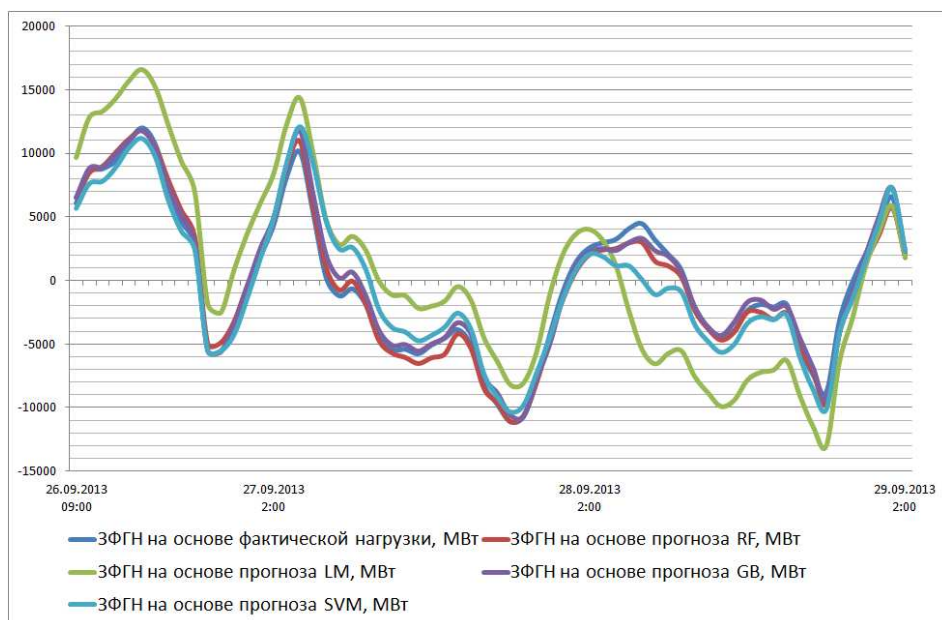


Рис. 3. Вычисленная знакопеременная функция генерации накопителей.

Как показали результаты расчетов (рис. 3), для покрытия накопителями дисбаланса между генерацией и потреблением энергии необходимо как минимум 12 ГВт суммарной мощности накопителей.

4. Заключение

В данной статье предложена новая математическая модель работы накопителей, которая позволяет учитывать динамику КПД при нелинейной зависимости от времени использования накопителей и функции изменения мощности работы накопителей. Также предложена прогнозная модель электрической нагрузки на сутки вперед, основанная на известных моделях машинного обучения. Прогноз нагрузки используется в качестве входного параметра для модели накопителя энергии. Предложенные модели тестируются на реальных данных ЭЭС Германии. Полученные прогнозы нагрузки показывают абсолютную ошибку до 2,77%. Сравнение различных прогнозных моделей показывает, что наилучшие результаты достигаются с помощью моделей на основе ансамблей решающих деревьев случайный лес и градиентный бустинг. По результатам расчётов при таком качестве прогноза для полного покрытия накопителями дисбаланса между генерацией и потреблением энергии необходимо как минимум 12 ГВт суммарной мощности накопителей.

Список литературы

1. Анушина Е. С. Система краткосрочного прогнозирования электрической нагрузки : автореф. дис. ... канд. техн. наук : 05.09.03 – электротехнические комплексы и системы. СПб., 2009. 18 с.
2. Карамов Д. Н. Математическое моделирование автономной системы электропитания, использующей возобновляемые источники энергии // Вестн. Иркут. гос. техн. ун-та. 2015. Вып. 104, № 9. С. 133–140.
3. Тихонов Э. Е. Методы прогнозирования в условиях рынка. Невинномысск : Невинномыс. технол. ин-т (Фил.) СевКавГТУ, 2006. 220 с.
4. Ali Mohd H., Wu B., Dougal R. A. An overview of SMES applications in power and energy systems // IEEE Transactions on Sustainable Energy. 2010. Vol. 1, N 1. P. 38–47. <https://doi.org/10.1109/tste.2010.2044901>
5. Breiman L. Random forests // Machine learning. 2001. Vol. 45, N 1. P. 5–32.
6. Di Silvestre M. L., Sanseverino E. R. Modelling energy storage systems using Fourier analysis: An application for smart grids optimal management // Applied Soft Computing. 2014. Vol. 14. P. 469–481. <https://doi.org/10.1016/j.asoc.2013.08.018>
7. Dufo-López R., Lujano-Rojas J. M., Bernal-A. J. Comparison of different lead-acid battery lifetime prediction models for use in simulation of stand-alone photovoltaic systems // Applied Energy. 2014. Vol. 115. P. 242–253. <https://doi.org/10.1016/j.apenergy.2013.11.021>
8. Dunn B., Kamath H., Tarascon J.-M. Electrical energy storage for the grid: a battery of choices // Science. 2011. Vol. 334, N 6058. P. 928–935. <https://doi.org/10.1126/science.1212741>
9. Dursun E., Kilic O. Comparative evaluation of different power management strategies of a stand-alone PV/Wind/PEMFC hybrid power system // International Journal of Electrical Power & Energy Systems. 2012. Vol. 34, N 1. P. 81–89. <https://doi.org/10.1016/j.ijepes.2011.08.025>
10. Drucker H., Burges C. J., Kaufman L. et al. Support vector regression machines // Advances in neural information processing systems. 1997. P. 155–161.
11. Friedman J. H. Stochastic gradient boosting // Computational Statistics & Data Analysis. 2002. Vol. 38, N 4. P. 367–378. [https://doi.org/10.1016/s0167-9473\(01\)00065-2](https://doi.org/10.1016/s0167-9473(01)00065-2)
12. Karellas S., Tzouganatos N. Comparison of the performance of compressed-air and hydrogen energy storage systems: Karpathos island case study // Renewable and Sustainable Energy Reviews. 2014. Vol. 29. P. 865–882. <https://doi.org/10.1016/j.rser.2013.07.019>
13. Kuster C., Rezgui Y., Mourshed M. Electrical load forecasting models: A critical systematic review // Sustainable Cities and Society. 2017. Vol. 35. P. 257–270. <https://doi.org/10.1016/j.scs.2017.08.009>
14. Makarov Y. V., Du P., Kintner-Meyer M. C. W. et al. Sizing energy storage to accommodate high penetration of variable energy resources // IEEE Transactions on Sustainable Energy. 2012. Vol. 3, N 1. P. 34–40. <https://doi.org/10.1109/tste.2011.2164101>
15. Muftahov I., Tynda A., Sidorov D. Numeric solution of Volterra integral equations of the first kind with discontinuous kernels // Journal of Computational and Applied Mathematics. 2017. Vol. 313. P. 119–128. <https://doi.org/10.1016/j.cam.2016.09.003>
16. Noriega J. R., Iyore O. D., Budime C. et al. Characterization system for research on energy storage capacitors // Review of Scientific Instruments. 2013. Vol. 84, N 5. P. 055109. <https://doi.org/10.1063/1.4804165>

17. Oza N. C. Online bagging and boosting // 2005 IEEE International Conference on Systems, Man and Cybernetics. 2005. Vol. 3. P. 2340–2345.
<https://doi.org/10.1109/icsmc.2005.1571498>
18. Punys P., Baublys R., Kasiulis E. et al. Assessment of renewable electricity generation by pumped storage power plants in EU Member States // Renewable and Sustainable Energy Reviews. 2013. Vol. 26. P. 190–200.
<https://doi.org/10.1016/j.rser.2013.05.072>
19. Sebastián R., Alzola R. P. Flywheel energy storage systems: Review and simulation for an isolated wind power system // Renewable and Sustainable Energy Reviews. 2012. Vol. 16, N 9. P. 6803–6813.
<https://doi.org/10.1016/j.rser.2012.08.008>
20. Sidorov D. N. Volterra equations of the first kind with discontinuous kernels in the theory of evolving systems control // Studia Informatica Universalis. 2011. Vol. 9, N 3. P. 135–146.
21. Sidorov D. N. Integral dynamical models: singularities, signals and control. World Scientific, 2015. 300 p. <https://doi.org/10.1142/9278>
22. Sizikov V. S. Further development of the new version of a posteriori choosing regularization parameter in ill-posed problems // Intl. J. of Artificial Intelligence. 2015. Vol. 13, N 1. P. 184–199.
23. Tsuanyo D., Azoumah Y., Aussel D., Neveu P. Modeling and optimization of batteryless hybrid PV (photovoltaic)/Diesel systems for off-grid applications // Energy. 2015. Vol. 86. P. 152–163. <https://doi.org/10.1016/j.energy.2015.03.128>
24. Zhukov A. V., Sidorov D. N., Foley A. M. Random forest based approach for concept drift handling // International Conference on Analysis of Images, Social Networks and Texts. Springer. 2016. P. 69–77. https://doi.org/10.1007/978-3-319-52920-2_7

Денис Николаевич Сидоров, доктор физико-математических наук, профессор, Институт систем энергетики им. Л. А. Мелентьева СО РАН, 664033, г. Иркутск, ул. Лермонтова, 130, тел.: (3952)500-646 (код 258), Российская Федерация; Иркутский национальный исследовательский технический университет, 664074, г. Иркутск, ул. Лермонтова, 83, Российская Федерация; Иркутский государственный университет, 664003, Иркутск, ул. К. Маркса, 1, Российская Федерация (e-mail: dsidorov@isem.irk.ru).

Алексей Витальевич Жуков, младший научный сотрудник, Институт солнечно-земной физики СО РАН, 664033, г. Иркутск, ул. Лермонтова, 126а, Российская Федерация, (e-mail: zhukovalex13@gmail.com).

Ильдар Ринатович Муфтахов, программист, Иркутский информационно-вычислительный центр ОАО «РЖД», 664005, г. Иркутск, ул. Маяковского, 25, Российская Федерация; Институт систем энергетики им. Л. А. Мелентьева СО РАН, 664033, г. Иркутск, ул. Лермонтова, 130, Российская Федерация, (e-mail: ildar_sm@mail.ru).

Поступила в редакцию 14.11.18

Volterra Equation Based Models for Energy Storage Usage Based on Load Forecast in EPS with Renewable Generation

D. N. Sidorov

Melentiev Energy Systems Institute SB RAS, Irkutsk, Russian Federation; Irkutsk National Research Technical University, Irkutsk, Russian Federation; Irkutsk State University, Irkutsk, Russian Federation

A. V. Zhukov

Institute of Solar-Terrestrial Physics SB RAS, Irkutsk, Russian Federation; Melentiev Energy Systems Institute SB RAS, Irkutsk, Russian Federation

I. R. Muftahov

Irkutsk Computing Center of JSC Russian Railways, Irkutsk, Russian Federation; Melentiev Energy Systems Institute SB RAS, Irkutsk, Russian Federation

Abstract. High penetration of renewable energy under condition of the free electricity market leads to the need of creating new methods for maintaining balance between load and generation, in particular, energy storage usage in modern power systems. However, most of the proposed models of energy storage do not take into account some important parameters, such as the nonlinear dependence of efficiency on life time and changes in capacity over time, the distribution of load between several independent storages and others. In order to solve this problem models based on Volterra integral equations of the first kind with kernels presented in the form of discontinuous functions are proposed. Such models allows to determine the alternating power function at known values of load and generation. However, to effectively solve this problem, an accurate forecast of the electrical load is required, therefore, several forecasting models based on machine learning was exploited. Forecasting models use different kind of features such as average daily temperature, load values with time shift, moving averages and others. In the paper comparison of the forecasting results is provided, including random forest, gradient boosting over the decision trees, the support vector machine, and also multiparameter linear regression. Effectiveness of the proposed forecasting models and storage model is demonstrated on the real data of Germany power system.

Keywords: Volterra equation, machine learning, forecasting, electric power systems, energy storage.

References

1. Anushina E.S. Sistema kratkosrochnogo prognozirovaniya jelektricheskoy nagruzki [Short-term forecasting system electrical load]. *Ph.D. thesis spec. Electrotechnical complexes and systems*, 2009. (in Russian)
2. Karamov D.N. Matematicheskoe modelirovanie avtonomnoy sistemy elektrosnabzheniya, ispol'zuyushchey vozobnovlyaemye istochniki energii [Mathematical modeling of autonomous electricity supply power system using renewable energy

- sources]. *Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta [Bulletin of Irkutsk State University]*, 2015, vol. 104, no. 9, pp. 133–140. (in Russian)
3. Tihonov J.E. Metody prognozirovaniya v usloviyah rynka [Forecasting methods in market conditions]. *Nevinnomysskiy tekh. in-t (fil.) SevKavGTU*, 2006. (in Russian)
 4. Ali Mohd H., Wu B., Dougal R.A. An overview of SMES applications in power and energy systems. *IEEE Transactions on Sustainable Energy*, 2010, vol. 1, no. 1, pp. 38–47. <https://doi.org/10.1109/tste.2010.2044901>
 5. Breiman L. Random forests. *Machine learning*, 2001, vol. 45, no. 1, pp. 5–32.
 6. Di Silvestre M.L., Sanseverino E.R. Modelling energy storage systems using Fourier analysis: An application for smart grids optimal management. *Applied Soft Computing*, 2014, vol. 14, pp. 469–481. <https://doi.org/10.1016/j.asoc.2013.08.018>
 7. Dufó-López R., Lujano-Rojas J.M., Bernal-A.J. Comparison of different lead-acid battery lifetime prediction models for use in simulation of stand-alone photovoltaic systems. *Applied Energy*, 2014, vol. 115, pp. 242–253. <https://doi.org/10.1016/j.apenergy.2013.11.021>
 8. Dunn B., Kamath H., Tarascon J.-M. Electrical energy storage for the grid: a battery of choices. *Science*, 2011, vol. 334, no. 6058, pp. 928–935. <https://doi.org/10.1126/science.1212741>
 9. Dursun E., Kilic O. Comparative evaluation of different power management strategies of a stand-alone PV/Wind/PEMFC hybrid power system. *International Journal of Electrical Power & Energy Systems*, 2012, vol. 34, no. 1, pp. 81–89. <https://doi.org/10.1016/j.ijepes.2011.08.025>
 10. Drucker H., Burges C.J., Kaufman L. et al. Support vector regression machines. *Advances in neural information processing systems*, 1997, pp. 155–161.
 11. Friedman J.H. Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 2002, vol. 38, no. 4, pp. 367–378. [https://doi.org/10.1016/s0167-9473\(01\)00065-2](https://doi.org/10.1016/s0167-9473(01)00065-2)
 12. Karellas S., Tzouganatos N. Comparison of the performance of compressed-air and hydrogen energy storage systems: Karpathos island case study. *Renewable and Sustainable Energy Reviews*, 2014, vol. 29, pp. 865–882. <https://doi.org/10.1016/j.rser.2013.07.019>
 13. Kuster C., Rezgui Y., Mourshed M. Electrical load forecasting models: A critical systematic review. *Sustainable Cities and Society*, 2017, vol. 35, pp. 257–270. <https://doi.org/10.1016/j.scs.2017.08.009>
 14. Makarov Y.V., Du P., Kintner-Meyer M.C.W. et al. Sizing energy storage to accommodate high penetration of variable energy resources. *IEEE Transactions on Sustainable Energy*, 2012, vol. 3, no. 1, pp. 34–40. <https://doi.org/10.1109/tste.2011.2164101>
 15. Muftahov I., Tynda A., Sidorov D. Numeric solution of Volterra integral equations of the first kind with discontinuous kernels. *Journal of Computational and Applied Mathematics*, 2017, vol. 313 pp. 119–128. <https://doi.org/10.1016/j.cam.2016.09.003>
 16. Noriega J.R., Iyore O.D., Budime C. et al. Characterization system for research on energy storage capacitors. *Review of Scientific Instruments*, 2013, vol. 84, no. 5, pp. 055109. <https://doi.org/10.1063/1.4804165>
 17. Oza N.C. Online bagging and boosting. *2005 IEEE International Conference on Systems, Man and Cybernetics*, 2005, vol. 3, pp. 2340–2345. <https://doi.org/10.1109/icsmc.2005.1571498>
 18. Punys P., Baublys R., Kasiulis E. et al. Assessment of renewable electricity generation by pumped storage power plants in EU Member States. *Re-*

- newable and Sustainable Energy Reviews*, 2013, vol. 26, pp. 190–200. <https://doi.org/10.1016/j.rser.2013.05.072>
19. Sebastián R., Alzola R.P. Flywheel energy storage systems: Review and simulation for an isolated wind power system. *Renewable and Sustainable Energy Reviews*, 2012, vol. 16, no. 9, pp. 6803–6813. <https://doi.org/10.1016/j.rser.2012.08.008>
 20. Sidorov D.N. Volterra equations of the first kind with discontinuous kernels in the theory of evolving systems control. *Studia Informatica Universalis*, 2011, vol. 9, no. 3, pp. 135–146.
 21. Sidorov D.N. Integral dynamical models: singularities, signals and control. *World Scientific*, 2015, 300 p. <https://doi.org/10.1142/9278>
 22. Sizikov V.S. Further development of the new version of a posteriori choosing regularization parameter in ill-posed problems. *Intl. J. of Artificial Intelligence*, 2015, vol. 13, no. 1, pp. 184–199.
 23. Tsuanyo D., Azoumah Y., Aussel D., Neveu P. Modeling and optimization of batteryless hybrid PV (photovoltaic)/Diesel systems for off-grid applications. *Energy*, 2015, vol. 86, pp. 152–163. <https://doi.org/10.1016/j.energy.2015.03.128>
 24. Zhukov A.V., Sidorov D.N., Foley A.M. Random forest based approach for concept drift handling. *International Conference on Analysis of Images, Social Networks and Texts*, Springer, 2016, pp. 69–77. https://doi.org/10.1007/978-3-319-52920-2_7

Denis Sidorov, Doctor of Sciences (Physics and Mathematics), Professor, Melentiev Energy Systems Institute SB RAS, 130, Lermontov st., Irkutsk, 664033, Russian Federation, tel.: (3952) 500-646 ext. 258; Irkutsk National Research Technical University, 83, Lermontov st., Irkutsk, 664074, Russian Federation; Irkutsk State University, 1, K. Marx st., Irkutsk, 664003, Russian Federation (e-mail: dsidorov@isem.irk.ru).

Aleksei Zhukov, Junior Research Scientist, Institute of Solar-Terrestrial Physics SB RAS, 126a, Lermontov st., Irkutsk, 664033, Russian Federation, (e-mail: zhukovalex13@gmail.com).

Ildar Muftahov, Programmer, Irkutsk Computing Center of Joint Stock Company Russian Railways, 25, Mayakovskii st., Irkutsk, 664005, Russian Federation; Melentiev Energy Systems Institute SB RAS, 130, Lermontov st., Irkutsk, 664033, Russian Federation (e-mail: ildar_sm@mail.ru).

Received 14.11.18