

ЭЛЕКТРОЭНЕРГЕТИКА

УДК 621.31

Ирина Александровна Лукичева

ФГБОУВО «Нижегородский государственный технический университет имени Р.Е. Алексеева», аспирант кафедры электроэнергетики, электроснабжения и силовой электроники, Россия, Нижний Новгород, e-mail: Lukicheva.ir@gmail.com

Александр Леонидович Куликов

ФГБОУВО «Нижегородский государственный технический университет имени Р.Е. Алексеева», доктор технических наук, профессор кафедры электроэнергетики, электроснабжения и силовой электроники, Россия, Нижний Новгород, e-mail: inventor61@mail.ru

Многомодельная оценка состояния энергосистемы на основе линейных переходных моделей

Авторское резюме

Состояние вопроса. Оценивание состояния энергосистемы является одной из важнейших функций центров контроля и управления в электроэнергетике. В последние годы с увеличением числа распределенных, в том числе возобновляемых, источников электроэнергии, электромобилей, появлением технологий управления спросом, возросшим риском кибератак сложность задачи оценивания состояния энергосистемы значительно увеличивается. В этих условиях большим потенциалом обладают методы оценивания состояния, которые учитывают информацию о корреляции состояний системы во времени, описываемой переходной моделью. Известные методы оценки состояния используют, как правило, одну единственную модель. Однако в условиях стохастического характера нагрузки и генерации нельзя утверждать об адекватности выбранной модели на всем интервале наблюдения. В связи с этим актуальным является разработка метода многомодельной прогнозной оценки состояния энергосистемы, обладающей низкими ошибками по сравнению с одномодельной оценкой в моменты наименьшей точности последней.

Материалы и методы. Используется многомодельное оценивание параметров с применением трех процедур одномодельных оценок фильтрации Калмана и различных переходных моделей на основе авторегрессионного и векторно-авторегрессионного анализов, а также экспоненциального сглаживания Хольта. Объединение одномодельных оценок произведено по критерию минимума дисперсии результирующей оценки.

Результаты. Разработан алгоритм многомодельной оценки состояния энергосистемы. Дан анализ его варианта с использованием трехмодельной прогнозной оценки, включающей линейные переходные модели. Путем имитационного моделирования произведена оценка состояния 30-узловой тестовой энергосистемы IEEE. Установлено максимальное повышение точности многомодельной оценки по сравнению с одномодельной: для авторегрессионного анализа – 26,1 %; векторно-регрессионного анализа – 16,9 %; сглаживания Хольта – 37,7 %.

Выводы. Предложенный метод многомодельной оценки состояния обладает большой устойчивостью и высокой точностью в моменты наименьшей точности одномоделной оценки. Целесообразно его применение в задачах управления энергосистемами, обладающими быстроизменяющимися динамическими режимами.

Ключевые слова: авторегрессия, векторная авторегрессия, многомодельный фильтр Калмана, прогнозируемая оценка состояния энергосистемы, экспоненциальное сглаживание Хольта

Irina Aleksandrovna Lukicheva

Nizhny Novgorod State Technical University, Postgraduate of the Department of Electric Power Engineering, Electric Power Supply and Power Electronics, Russia, Nizhny Novgorod, e-mail: Lukicheva.ir@gmail.com

Alexander Leonidovich Kulikov

Nizhny Novgorod State Technical University, Doctor of Engineering Sciences, Professor of the Department of Electric Power Engineering, Electric Power Supply and Power Electronics, Russia, Nizhny Novgorod, e-mail: inventor61@mail.ru

Multi-model power system state estimation based on linear transition models

Abstract

Background. Power system state estimation is one of the most important functions of power system control centers. In recent years, the complexity of power system state estimation has significantly increased due to the growing number of distributed, including renewable energy sources, electric vehicles, the demand response technologies, and the increased risk of cyber-attacks. Under these conditions, state estimation methods, which consider information about the time-correlation of the power system states have a great potential. The correlation is described by a transition model. The well-known state estimation methods usually use one single model. However, in case of stochastic behavior of the load and generation, it is impossible to assert the adequacy of the chosen model over the entire observation interval. Therefore, the paper proposes a multi-model forecasting power system state estimation method, which has lower errors in comparison with a single-model assessment at the moments of the lowest accuracy of the latter.

Materials and methods. Multi-model parameter estimation is used based on three procedures of the single-model Kalman filtering estimation and various transition models based on autoregressive and vector autoregressive analyzes, as well as Holt's exponential smoothing. Uniting the single-model estimation has been carried out according to the criterion of the minimum of variance of the resulting estimate.

Results. An algorithm of multi-model power system state estimation has been developed. Its version has been analyzed using a three-model forecasting-aided estimation using linear transition models. The state of the IEEE 30-bus test power system has been assessed by the means of simulation modeling. The maximum accuracy increase of the multi-model estimation in comparison with the single model is set up. 26,1 % is for autoregressive analysis; 16,9 % is for vector regression analysis and 37,7 % is for Holt's exponential smoothing.

Conclusions. The proposed method of multi-model state estimation has higher robustness and accuracy at the moments of the lowest accuracy of single-model estimation. It is advisable to use the method to solve control tasks of power systems with rapidly changing dynamic modes.

Key words: autoregression, vector autoregression, multimodel Kalman filter, forecasting power system state estimation, Holt's exponential smoothing

DOI: 10.17588/2072-2672.2021.1.031-040

Введение. Статическая оценка состояния (ОС), являющаяся стандартной процедурой при анализе работы энергосистемы, необходима для уточнения параметров режима по данным избыточных измерений в определенные моменты времени и, как правило, реализуется с использованием метода взвешенных наименьших квадратов (ВНК) [1]. Однако при таком под-

ходе информация о состоянии системы в предшествующие последовательные моменты времени не учитывается. В ряде работ, например [2], предложено использовать информацию об изменениях состояния системы с помощью квазидинамической ОС. Такой вариант оценивания получил название прогнозируемой оценки состояния (ПОС) [3–5]. Допущение в этом ме-

тоде состоит в том, что система имеет медленно изменяющиеся состояния, и ошибки измерения распределены по гауссовскому закону с нулевым средним и известной ковариацией.

ПОС имеет ряд преимуществ перед статической ОС. В статической ОС используется совокупность измерений, зафиксированных в один и тот же момент времени. При этом решающее значение приобретает избыточность измерений, а также централизованный подход к ОС. В случае нарушений работы каналов связи, потери измерений, их задержки реализация ОС затрудняется. Статическая ОС, выполняемая методом ВНК, чувствительна к выбросам, которые существенно искажают результаты оценки. ПОС использует информацию о предыдущих состояниях, что позволяет проводить дополнительный анализ для обнаружения выбросов, а ошибочные или потерянные измерения заменить прогнозом состояния. Комбинация анализа невязки и выбросов позволяет различать внезапные изменения в системе, неверные данные или кибератаки, ошибки в конфигурации сети, а также в задании сетевых параметров [3]. При ПОС измерения, выполненные в различных узлах сети, могут обрабатываться независимо, поэтому оценка состояния соответствует децентрализованному подходу. ПОС может дополнительно использоваться как источник псевдоизмерений для статической ОС в целях снижения ошибок оценки. ПОС позволяет наблюдать динамические процессы, что является особенно актуальным в электрических сетях с прерывистой нагрузкой и распределенной генерацией.

Как правило, вычисление ПОС состоит из двух этапов – прогнозирования и фильтрации состояния, причем для реализации последней привлекается фильтрация Калмана. Прогноз состояния выполняется на основе переходной модели, выбор которой имеет важнейшее значение для обеспечения адекватности ПОС. Широкое распространение получили такие методы формирования переходной модели, как авторегрессионный анализ и экспоненциальное сглаживание Хольта [5–10]. Оригинальный способ построения модели перехода был предложен в [11], где поочередно использовались модель постоянных параметров сигналов или линейная модель изменения параметров сигналов в зависимо-

сти от динамичности режима. Однако в [5–11] учитывается только временная корреляция состояний, а пространственная корреляция между напряжениями узлов, соединенных друг с другом [12], не используется. Преимущества применения пространственных корреляций позволяет получить введение модели векторной авторегрессии (VAR). В [13] предложено краткосрочное прогнозирование узлового вектора напряжения в энергосистемах с большим количеством микросетей и ветряных электростанций. В [13] использовались модели AR и VAR, причем выбор между ними производился на основе характеристик электрической сети, таких как возможность подключения к электрическим узлам, центральность, формируемая как величина, обратная расстоянию от узла до других узлов системы, и значимость, определяемая величиной мощности нагрузки или генерации, подключенной к узлу. Однако на разных временных отрезках, соответствующих текущему режиму электрической сети, различные модели могут показывать лучшие результаты. Нами предлагается многомодельная прогнозируемая оценка состояния, позволяющая за счет оптимальной комбинации одномодельных оценок получать результирующую многомодельную оценку большей точности.

Методы исследования.

А) *Прогнозируемая оценка состояния.* Рабочая группа по динамической оценке состояния (ДОС) и параметров энергосистемы Института инженеров по электротехнике и радиоэлектронике (IEEE Task force on *Power System Dynamic State and Parameter Estimation*) определяет ПОС как частный случай концепции ДОС, примененный к квазистатическим условиям, когда переходная модель определяется достаточно медленными стохастическими изменениями в нагрузке и генерации и динамикой состояния можно пренебречь [14]. Более того, принимается, что в ПОС переходная модель – линейная, в отличие от нелинейной в ДОС. Тогда уравнения, описывающие ПОС, принимают следующий вид:

$$x_{k+1} = F_k x_k + u_k + \omega_k; \quad (1)$$

$$y_{k+1} = h(x_{k+1}) + v_k, \quad (2)$$

где x_k – вектор состояния, включающий амплитуды и углы напряжений; $h(x_k)$ – функция отношения между измерениями y_k и состоя-

нием x_k ; ω_k и v_k – белые шумы с математическим ожиданием, равным нулю (некоррелированы и характеризуются ковариационными матрицами Q_k и R_k соответственно):

$$\omega_k \sim (0, Q_k), \quad v_k \sim (0, R_k), \quad E[\omega_k \omega_j^T] = Q_k \delta_{k-j},$$

$$E[v_k v_j^T] = R_k \delta_{k-j}, \quad E[v_k \omega_j^T] = 0,$$

где δ_{k-j} – дельта-функция Кронекера; переходная матрица F_k и вектор тренда u_k определяются по историческим данным временных рядов.

Для решения задач ПОС на практике наибольшее распространение получил фильтр Калмана. Фильтр Калмана – рекурсивный фильтр, оценивающий вектор состояния динамической системы с использованием ряда неполных и искаженных («зашумленных») измерений. Задача калмановской фильтрации состоит в определении математического ожидания и дисперсии оцениваемого параметра x_k , изменяющегося по определенному закону, на основе измерений y_k .

Различают апостериорную и априорную оценки. Апостериорная оценка может быть вычислена при наличии измерений до момента времени k включительно и соответствует условному математическому ожиданию параметра при условии измерений от y_1 до y_k :

$$\hat{x}_k = E[x_k | y_1, y_2, \dots, y_k]. \quad (3)$$

Априорная оценка определяется при наличии измерений до момента времени k , не включает измерение k и соответствует выражению

$$\tilde{x}_k = E[x_k | y_1, y_2, \dots, y_{k-1}]. \quad (4)$$

Взаимосвязь погрешностей результатов оценки параметров характеризуется ковариациями P_k : \tilde{P}_k – априорной оценки;

\hat{P}_k – апостериорной оценки:

$$\tilde{P}_k = E[(x_k - \tilde{x}_k)(x_k - \tilde{x}_k)^T], \quad (5)$$

$$\hat{P}_k = E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T].$$

Проиллюстрируем расчеты согласно алгоритму фильтрации Калмана. Пусть линейная система описывается выражениями:

$$x_k = F_{k-1}x_{k-1} + u_{k-1} + \omega_{k-1}; \quad (6)$$

$$y_k = H_k x_k + v_k, \quad (7)$$

где H_k – матрица коэффициентов линейного отношения между измерениями y_k и состоянием x_k .

Измерение параметра производится в дискретные моменты времени t_k ($k=1, 2, \dots$)

с одинаковым шагом $T = t_{k+1} - t_k$. Оптимальная процедура обработки текущих отсчетов сводится при этом к следующему алгоритму [15–16]:

1. По результатам $(k-1)$ предшествующих измерений в моменты времени t_1, t_2, \dots, t_{k-1} вырабатывается результирующая оценка параметра \hat{x}_{k-1} и ковариация ошибки оценки \hat{P}_{k-1} .

2. Полученная оценка прогнозируется на k -й шаг, в результате чего формируется доопытная (априорная) оценка \tilde{x}_k :

$$\tilde{x}_k = F_{k-1}\hat{x}_{k-1} + u_{k-1}. \quad (8)$$

Уравнение (8) называется уравнением обновления.

3. Вычисляется ковариация ошибки априорной оценки согласно выражению

$$\tilde{P}_k = F_{k-1}\hat{P}_{k-1}F_{k-1}^T + Q_{k-1}. \quad (9)$$

4. В момент t_{k+1} производится измерение параметра y_k .

5. На основе оценки \tilde{x}_k и измерения y_k формируется результирующая (апостериорная) оценка параметра \hat{x}_k на k -м шаге и ковариация ее ошибки:

$$\hat{x}_k = \tilde{x}_k + K_k(y_k - H_k\tilde{x}_k); \quad (10)$$

$$P_k = (I - K_k H_k)\tilde{P}_k, \quad (11)$$

где K_k – коэффициент усиления Калмана; I – единичная матрица.

Результирующая оценка (10) является взвешенной суммой априорной оценки и измерения, при этом вес определяется коэффициентом усиления Калмана K_k , вычисляемого исходя из условия минимизации ошибки апостериорной оценки:

$$K_k = \tilde{P}_k H_k^T (H_k \tilde{P}_k H_k^T + R_k)^{-1}. \quad (12)$$

После вычисления оценки \hat{x}_k (10) цикл измерений повторяется и аналогично формируются оценки на $(k+1)$ -м, $(k+2)$ -м и т.д. шагах. Таким образом, процедура оценки параметра оказывается рекуррентной.

Калмановская фильтрация обеспечивает результаты с минимальными ошибками при соблюдении следующих допущений:

1) ошибки оценки параметров и измерений распределены по нормальному закону с математическим ожиданием равным нулю;

2) ковариации ошибок оценки параметров и измерений известны;

3) известна точная математическая модель пересчета параметров от шага к шагу.

В реальности в условиях стохастического изменения генерации и нагрузки в электрических сетях указанные допущения становятся достаточно грубыми. Из-за случайного поведения нагрузок и режимов возобновляемых источников энергии не существует единой универсальной модели перехода, с помощью которой можно было бы точно прогнозировать изменения оцениваемого параметра во времени. На разных временных отрезках различные переходные модели могут показывать лучшие результаты. Поэтому ниже предлагается многомодельная прогнозируемая оценка состояния (ММПОС), позволяющая реализовать одновременное использование нескольких моделей [17]. Общее схематическое изображение алгоритма многомодельной оценки представлено на рис. 1.

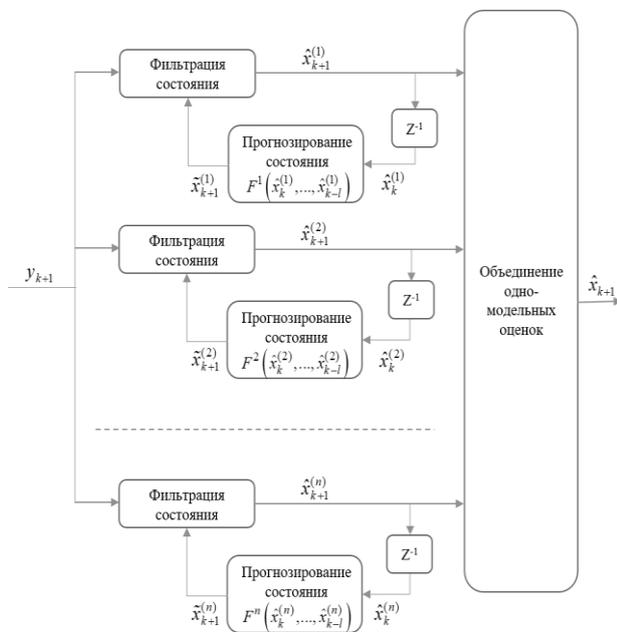


Рис. 1. Структура многомодельной прогнозируемой оценки

Б) *Алгоритм многомодельной прогнозируемой оценки.* Многомодельный прогнозирующий оценщик (МПО) состоит из нескольких одноmodelных прогнозирующих оценщиков (ОПО) и блока объединения одноmodelных оценок (рис. 1). В каждом ОПО расчеты реализуются в два этапа: 1) вычисление априорной оценки в соответствии с выражениями (1)–(2) и моделью перехода F^i ; 2) получение апостериорной оценки (10). В блоке объединения оценок формируется результирующая мно-

гомодельная оценка путем взвешенного суммирования одноmodelных оценок $\hat{X}_k^{(n)}$.

В) *Переходные модели.* В качестве составляющих многомодельной оценки использовались три фильтра Калмана с различными переходными моделями: авторегрессионная первого порядка; векторная авторегрессионная первого порядка; экспоненциальное сглаживание Хольта.

1) *Экспоненциальное сглаживание Хольта.* Прогнозное значение параметра определяется как сумма экспоненциально-сглаженного значения параметра a_k и тренда его изменения b_k :

$$\tilde{X}_{k+1} = a_k + b_k. \tag{13}$$

Экспоненциально-сглаженное значение параметра и тренд также оцениваются на каждом шаге:

$$a_k = \alpha \tilde{X}_k + (\alpha - 1) \tilde{X}_{k-1}; \tag{14}$$

$$b_k = \beta [a_k - a_{k-1}] + (1 - \beta) b_{k-1}, \tag{15}$$

где α и β – сглаживающие коэффициенты, принимающие значения от 0 до 1.

2) *Модель авторегрессии первого порядка AR.* Использование авторегрессионного анализа эффективно с точки зрения вычислительной нагрузки, поэтому этот метод широко используется в алгоритмах ПОС [18].

Модель $AR(p)$ – это модель, в которой значения временного ряда в текущий момент линейно зависят от предшествующих значений того же ряда:

$$X_{k+1} = \sum_{i=1}^p \varphi_i X_{k+1-i} + \varepsilon_{k+1}, \tag{16}$$

где φ_i – авторегрессионный коэффициент i -го порядка; ε_{k+1} – белый шум с нулевым средним и инвариантной во времени ковариационной матрицей; p – параметр, соответствующий количеству используемых предшествующих наблюдений.

3) *Модель векторной авторегрессии первого порядка VAR.* VAR-модель порядка p вычисляется согласно выражению

$$X_{k+1} = \Phi_1 X_k + \Phi_2 X_{k-1} + \dots + \Phi_n X_{k-n+1} + \varepsilon_{k+1}, \tag{17}$$

где Φ_i – матрица коэффициентов $n \times n$.

Г) *Взвешенная сумма одноmodelных оценок.* Критерием оптимальности взвешенной суммы одноmodelных оценок будем считать минимум ковариации результирующей многомодельной оценки.

Рассмотрим объединение двух оценок. Для простоты восприятия далее индекс k опускается. Пусть $\hat{X}^{(1)}$ и $\hat{X}^{(2)}$ оценки одно-

модельных оценщиков, соответствующие одному из дискретных шагов схемы (рис. 1). Тогда линейная комбинация этих двух оценок будет определяться взвешенной суммой $\hat{x}^{(1)}$ и $\hat{x}^{(2)}$, причем вес α соответствует соотношению их точности:

$$\hat{x} = (1 - \alpha)\hat{x}^{(1)} + \alpha\hat{x}^{(2)}, \quad (18)$$

где α – коэффициент, принимающий значения от 0 до 1.

Очевидно, что оценки параметров электроэнергетических систем могут быть представлены случайными величинами, имеющими определенный закон статистического распределения. Тогда точность оценки параметров электроэнергетических систем целесообразно характеризовать дисперсией их распределений [19]. Имея выборочные значения, распределенные по нормальному закону, $\hat{x}^{(i)} \sim N(\mu_{\hat{x}^{(i)}}, \sigma_{\hat{x}^{(i)}}^2)$ и

$$\mu_{\hat{x}} = \sum_{i=1}^n \alpha_i \mu_{\hat{x}^{(i)}}, \quad \sigma_{\hat{x}}^2 = \sum_{i=1}^n \alpha_i \sigma_{\hat{x}^{(i)}}^2, \quad \text{преобразуем}$$

выражение (18) к виду

$$\sigma_{\hat{x}}^2 = (1 - \alpha)^2 \sigma_{\hat{x}^{(1)}}^2 + \alpha^2 \sigma_{\hat{x}^{(2)}}^2. \quad (19)$$

Из выражения (19) следует, что коэффициент α должен быть подобран таким образом, чтобы результирующее значение дисперсии $\sigma_{\hat{x}}^2$ принимало минимальное значение. Возьмем производную от выражения (19) и, приравняв ее к нулю, получим оптимальное значение коэффициента α :

$$\alpha = \frac{\sigma_{\hat{x}^{(1)}}^2}{\sigma_{\hat{x}^{(1)}}^2 + \sigma_{\hat{x}^{(2)}}^2}. \quad (20)$$

Подставляя (20) в (18), получаем:

$$\hat{x} = \frac{\sigma_{\hat{x}^{(2)}}^2}{\sigma_{\hat{x}^{(1)}}^2 + \sigma_{\hat{x}^{(2)}}^2} \cdot \hat{x}^{(1)} + \frac{\sigma_{\hat{x}^{(1)}}^2}{\sigma_{\hat{x}^{(1)}}^2 + \sigma_{\hat{x}^{(2)}}^2} \cdot \hat{x}^{(2)}, \quad (21)$$

$$\sigma_{\hat{x}}^2 = \frac{1}{\frac{1}{\sigma_{\hat{x}^{(1)}}^2} + \frac{1}{\sigma_{\hat{x}^{(2)}}^2}} = \frac{1}{v^{(1)} + v^{(2)}}, \quad (22)$$

$$\text{где } v^{(i)} = \frac{1}{\sigma_{\hat{x}^{(i)}}^2}.$$

Следуя тому же принципу, рассмотрим случай множественного объединения оценок для формирования результирующей оценки с минимальной дисперсией. Выражения для множественного объединения скалярных оценок [20] принимают вид

$$\hat{x} = \sum_{i=1}^n \frac{v^{(i)}}{v^{(1)} + \dots + v^{(n)}} \cdot \hat{x}^{(i)}, \quad (23)$$

$$v_{\hat{x}} = \sum_{i=1}^n v^{(i)}. \quad (24)$$

Здесь при объединении векторных оценок используется выражение

$$\hat{x} = \sum_{i=1}^n A^{(i)} \hat{x}^{(i)}, \quad (25)$$

где $\sum_{i=1}^n A^{(i)} = I$; весовая матрица $A^{(i)}$ определяется из соотношения

$$A^{(i)} = \left(\sum_{j=1}^n (\Sigma^{(j)})^{-1} \right)^{-1} \cdot (\Sigma^{(i)})^{-1}, \quad (26)$$

где $\Sigma^{(i)}$ – ковариационная матрица i -й оценки $\hat{x}^{(i)}$.

В итоге результирующая оценка формируется на основе равенства

$$\hat{x} = \sum_{i=1}^n \left(\sum_{j=1}^n (\Sigma^{(j)})^{-1} \right)^{-1} \cdot (\Sigma^{(i)})^{-1} \hat{x}^{(i)}. \quad (27)$$

Результаты исследования. Предложенный метод МПО был протестирован на 30-узловой системе IEEE (рис. 2) [21]. Предполагалось, что к узлам 14, 16, 27 подключена ветрогенерация, на долю которой приходится около 5 % от общей выработки электроэнергии в системе. Соотношения мощности ветровой генерации распределились следующим образом: в узле 14–20 % от общей выработки, в узле 16–50 %, а в узле 27–30 %. Дополнительно значениям мощности ветровой генерации были добавлены случайные флуктуации, имеющие равномерное распределение с математическим ожиданием 2,5 % и среднеквадратическим отклонением 0,417 % от общей выработки.

Данные о ветровой генерации и структуре нагрузки были выбраны из открытых отчетов администрации энергокомпании Боневил (Bonneville Power Administration (BPA))¹. Пятиминутная частота дискретизации данных по нагрузке была увеличена до 30 секунд с помощью линейной интерполяции, аналогично [12]. При этом пятиминутный интервал данных нагрузки линейно интерполировался по 10 промежуточным точкам. Процент изменения нагрузки от текущего отсчета к последующему не превышал 0,2 %. В случайным образом выбранные периоды времени генерация и

¹ B. P. Administration. (2012) Wind generation total load in the bpabalancing authority. [Online]. <http://transmission.bpa.gov/business/operations/wind>

нагрузка в различных узлах схемы изменялись по различным графикам, в то время как общее потребление и генерация повторяли тренд реальных измерений, свойственных ВРА. Набор данных состоял из 2760 векторов состояний, что соответствовало 23 часам наблюдения. Вектор состояния представлял собой совокупность амплитуд и углов напряжения во всех пронумерованных узлах схемы и был получен путем расчета с использованием пакета Power Models в Julia (ACPPowerModel)². Случайность измеряемых величин имитировалась добавлением гауссовского шума к углам и амплитудам напряжения. Среднеквадратическое отклонение случайных фазовых углов напряжения было принято равным 0,02 градуса, а амплитуд напряжения – 1 %, что соответствует стандартным требованиям точности синхронизированных векторных измерений [22].

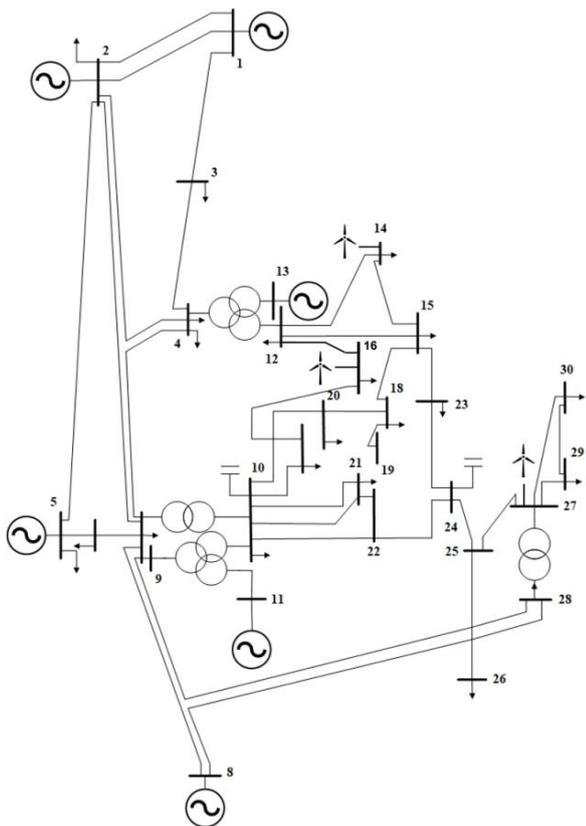


Рис. 2. Схема 30-узловой энергосистемы IEEE

Модельным экспериментам подлежала ММПСОС, включающая три фильтра Калмана (выражения (8)–(12)): 1) с авторегрессионной переходной моделью по выражению (16) (ПОС(АР1)); 2) с векторной

авторегрессионной переходной моделью по выражению (17) (ПОС(ВАР1)); 3) с применением экспоненциального сглаживания Хольта (13)–(15) (ПОС(ЭСХ)). Параметры сглаживания Хольта были выбраны такими же, как и в [10]: $\alpha = 0,5$ и $\beta = 0,8$.

На рис. 3 и 4 показаны реальные изменения значения фазового угла напряжения в узле 14, а также результаты его оценок с применением указанных выше моделей.

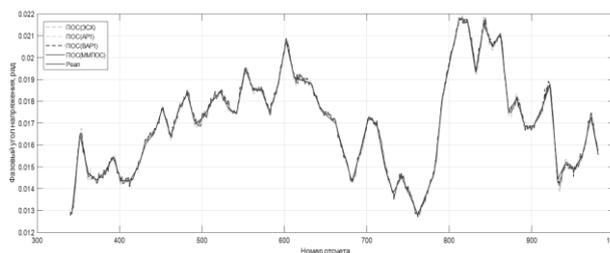


Рис. 3. Реальные изменения значения фазового угла напряжения в узле 14 и результаты его оценок

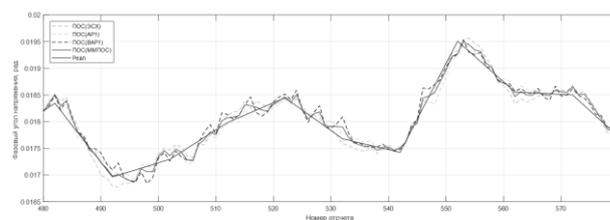


Рис. 4. Реальные изменения значения фазового угла напряжения в узле 14 и результаты его оценок в масштабе 100 отсчетов

Данные табл. 1, 2 характеризуют точность одномоделных оценок, ММПСОС и измерений, выраженную в процентах средней абсолютной процентной ошибки (MAPE) и среднеквадратичной ошибки (MSE), рассчитанных для различных временных интервалов:

$$MAPE^n = \frac{1}{T} \sum_{t=1}^T \left| \frac{\hat{x}_t^n - x_t^n}{x_t^n} \right| \cdot 100\%; \quad (28)$$

$$MSE^n = \frac{1}{T} \sum_{t=1}^T (\hat{x}_t^n - x_t^n)^2. \quad (29)$$

Значения минимальных ошибок, относящиеся к различным вариантам оценок, в табл. 1, 2 выделены жирным шрифтом. Следует отметить, что на различных временных интервалах ММПСОС практически всегда обеспечивает наилучшую точность оценивания. Такой эффект объясняется тем, что в условиях случайно изменяемых параметров электроэнергетической системы существует высокая вероятность того,

² PowerModels.jl Documentation. [Online]. <https://lanl-ansi.github.io/PowerModels.jl/stable/>

что из заданного набора моделей найдется наиболее близкая и соответствующая динамике режима сети.

Таблица 1. MAPE оценки фазового угла напряжения в узле 14 для различных оценщиков

MAPE, %			
Период/ Оценщик	640-660	1060-1080	1860-1880
Оценщик 1	0,069	0,078	0,101
Оценщик 2	0,086	0,070	0,074
Оценщик 3	0,078	0,108	0,073
ММПОС	0,068	0,072	0,065
Измерения	0,092	0,084	0,105

Таблица 2. MSE оценки фазового угла напряжения в узле 14 для различных оценщиков

MSE, 10-8			
Период/ Оценщик	640-660	1060-1080	1860-1880
Оценщик 1	1,50	7,92	4,28
Оценщик 2	2,27	5,90	2,86
Оценщик 3	1,52	9,07	2,78
ММПОС	1,24	6,36	2,10

На рис. 5 изображено распределение ошибок оценивания MAPE и MSE для всех узлов энергосистемы (рис. 2) за весь период наблюдения, полученных по результатам имитационного моделирования. Анализ полученных данных (рис. 5) показывает, что ММПОС обладает минимальной средней абсолютной ошибкой MAPE и незначительно отличается по минимальной среднеквадратической ошибке MSE от наилучшего результата. Максимальное повышение точности многомодельной оценки, по сравнению с одномодельной, составило: для авторегрессионного анализа – 26,1 %; векторно-регрессионного анализа – 16,9 %; сглаживания Хольта – 37,7 %.

вило: для авторегрессионного анализа – 26,1 %; векторно-регрессионного анализа – 16,9 %; сглаживания Хольта – 37,7 %.

Выводы. Оценивание состояния энергосистемы является одной из важнейших функций центров контроля и управления в электроэнергетике. Большим потенциалом обладают методы оценивания состояния, которые учитывают информацию о корреляции состояний системы во времени и используют переходную прогнозную модель.

Предложенный метод многомодельной прогнозной оценки состояния энергосистемы с применением трех процедур фильтрации Калмана и различными переходными моделями на основе авторегрессионного и векторно-авторегрессионного анализов, а также экспоненциального сглаживания Хольта обладает малыми ошибками по сравнению с одномодельной оценкой в моменты наименьшей точности последней.

Результаты имитационного моделирования 30-узловой системы IEEE с возобновляемыми источниками энергии показали, что максимальное повышение точности многомодельной оценки, по сравнению с одномодельной, составило: для авторегрессионного анализа – 26,1 %; векторно-регрессионного анализа – 16,9 %; сглаживания Хольта – 37,7 %.

Перспективным направлением дальнейшего исследования является применение ММПОС для защиты интеллектуальных электрических сетей от воздействия кибератак, использование нелинейных моделей в составе ММПОС, а также выбор вариантов одномодельных оценок и методов их объединения.

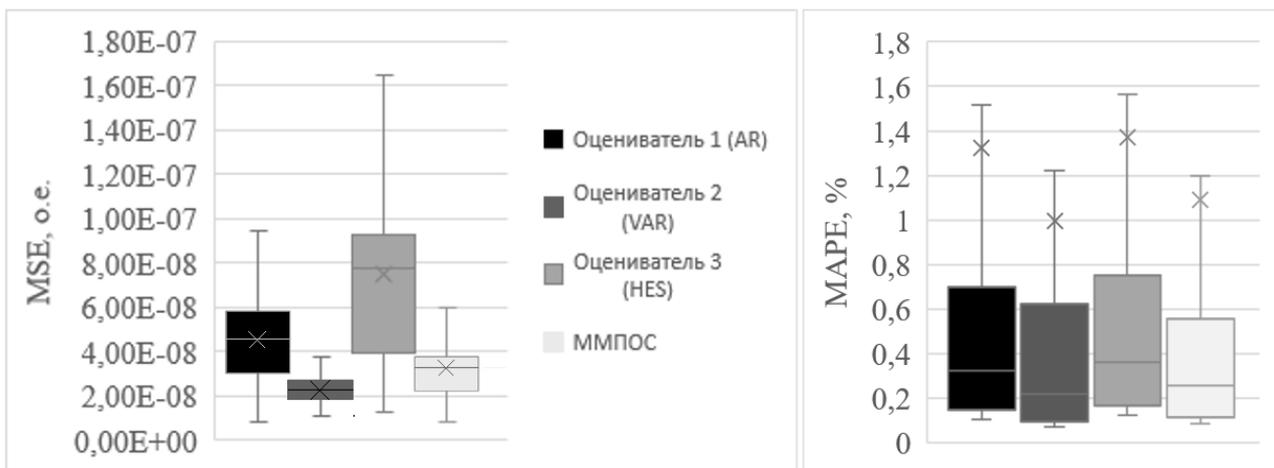


Рис. 5. Сравнение точности одномодельных и многомодельной оценок

Список литературы

1. **Гамм А.З.** Статистические методы оценивания состояния электроэнергетических систем. – М.: Наука, 1976. – 220 с.

2. **Debs A.S., Larson R.E.** A dynamic estimator for tracking the state of a power system // IEEE Trans. Power Appar. Syst. – 1970. – Vol. PAS-89, issue 7. – P. 1670–1678. DOI: 10.1109/TPAS.1970.292822

3. **Do Coutto Filho M.B., Stacchini de Souza J.C.** Forecasting-aided state estimation – part i: panorama // IEEE Trans. Power Syst. – 2009. – Vol. 24, issue 4. – P. 1667–1677. DOI: 10.1109/TPWRS.2009.2030295.

4. **Do Coutto Filho M.B., Glover J.D., Leite da Silva A.M.** State Estimators with Forecasting Capability // 11th Power systems computation, Avignon, France (Power Systems Computation Conference). – Avignon, 1993. – Vol. 2. – P. 689–695.

5. **Leite da Silva A.M., Do Coutto Filho M.B., de Queiroz J.F.** State forecasting in electric power systems // IEE Proc. C – Gener. Transm. Distrib. – 1983. – Vol. 130(5). – P. 237–244.

6. **Dynamic** state prediction based on autoregressive (ar) model using pmu data / F. Gao, J.S. Thorp, A. Pal, S. Gao // IEEE Power and Energy Conference. – Illinois, 2012. – P. 1–5.

7. **Zhao J., Zhang G., La Scala M.** PMU based robust dynamic state estimation method for power systems // IEEE Power & Energy Society General Meeting. Denver, 2015. – P. 1–5.

8. **Short-term** state forecasting-aided method for detection of smart grid general false data injection attacks / J. Zhao, G. Zhang, M. La Scala, et al. // IEEE Transactions on Smart Grid. – 2015. – Vol. 8, no. 4. – P. 1580–1590.

9. **Shih K.-R., Huang S.-J.** Application of a robust algorithm for dynamic state estimation of a power system // IEEE Transactions on Power Systems. – 2002. – Vol. 17, no. 1. – P. 141–147.

10. **Da Silva A.L., Do Coutto Filho M., Cantera J.** An efficient dynamic state estimation algorithm including bad data processing // IEEE transactions on Power Systems. – 1987. – Vol. 2, no. 4. – P. 1050–1058.

11. **Глазунова А.М., Колосок И.Н., Съемщиков Е.С.** Обнаружение некорректных данных при управлении интеллектуальной энергосистемой методами динамического оценивания состояния // Электричество. – 2017. – № 2. – С. 18–27.

12. **Hassanzadeh M., Evrenosoğlu C.Y., Mili L.** A short-term nodal voltage phasor forecasting method using temporal and spatial correlation // IEEE Transactions on Power Systems. – 2015. – Vol. 31, no. 5. – P. 3881–3890.

13. **Abur A., Exposito A.G.** Power system state estimation: theory and implementation. – CRC press, 2004.

14. **Power System Dynamic State Estimation: Motivations, Definitions, Methodologies, and Future Work** / J. Zhao, A. Comer-Exposito, M. Netto, et al. // IEEE Transactions on Power Systems. – 2019. – Vol. 34, no. 4. – P. 3188–3198. DOI: 10.1109/TPWRS.2019.2894769.

15. **Радиоэлектронные системы. Основы построения и теория: справочник.** – 2-е изд. перераб. и доп. / под ред. Я.Д. Ширмана. – М.: Радиотехника, 2007. – 512 с.

16. **Куликов А.Л.** Цифровое дистанционное определение повреждений ЛЭП / под ред. М.Ш. Мисриханова. – Н.Новгород: Изд-во ВВАГС, 2006. – 315 с.

17. **Куликов А.Л., Лукичева И.А.** Применение многомодельного подхода для оценки частоты электрической сети // Фёдоровские чтения – 2018: сб. тр. XLVIII Междунар. науч.-практ. конф. с элементами научной школы / под общ. ред. Б.И. Кудрина, Ю.В. Матюниной. – М., 2018. – С. 259–265.

18. **Mohammad H., Evrenosoğlu C.Y.** Power system state forecasting using regression analysis // IEEE Power and Energy Society General Meeting. IEEE, 2012.

19. **Sahoo Prasanna.** Probability and mathematical statistics. – University of Louisville, 2013.

20. **An elementary** introduction to kalman filtering / Y. Pel, S. Biswas, D.S. Fussell, K. Pingali // Communications of the ACM 62.11. – 2019. – P. 122–133.

21. **Urban** mv and lv distribution grid topology estimation via group lasso / Liao Yizheng, Yang Weng, Guangyi Liu, Ram Rajagopal // IEEE Transactions on Power Systems 34.1. – 2018. – P. 12–27.

22. **Synchrophasor** measurement accuracy characterization / A. Meliopoulos, V. Madani, D. Novosel, et al. // North American Synchro Phasor Initiative Performance & Standards Task Team (Consortium for Electric Reliability Technology Solutions). – 2007. – Vol. 10.

References

1. Gamm, A.Z. *Statisticheskie metody otsenivaniya sostoyaniya elektroenergeticheskikh sistem* [Statistical methods for the power systems state estimation]. Moscow: Nauka, 1976. 220 p.

2. Debs, A.S., Larson, R.E. A dynamic estimator for tracking the state of a power system. IEEE Trans. Power Appar. Syst., 1970, vol. PAS-89, issue 7, pp. 1670–1678. DOI: 10.1109/TPAS.1970.292822

3. Do Coutto Filho, M.B., Stacchini de Souza, J.C. Forecasting-aided state estimation – part i: panorama. IEEE Trans. Power Syst., 2009, vol. 24, issue 4, pp. 1667–1677. DOI: 10.1109/TPWRS.2009.2030295.

4. Do Coutto Filho, M.B., Glover, J.D., Leite da Silva, A.M. State Estimators with Forecasting Capability. 11th Power systems computation, Avi-

gnon, France (Power Systems Computation Conference). Avignon, 1993, vol. 2, pp. 689–695.

5. Leite da Silva, A.M., Do Coutto Filho, M.B., de Queiroz, J.F. State forecasting in electric power systems. IEE Proc. C – Gener. Transm. Distrib., 1983, vol. 130(5), pp. 237–244.

6. Gao, F., Thorp, J.S., Pal, A., Gao, S. Dynamic state prediction based on auto-regressive (ar) model using pmu data. IEEE Power and Energy Conference. Illinois, 2012, pp. 1–5.

7. Zhao, J., Zhang, G., La Scala, M. PMU based robust dynamic state estimation method for power systems. IEEE Power & Energy Society General Meeting. Denver, 2015, pp. 1–5.

8. Zhao, J., Zhang, G., La Scala, M., Dong, Z.Y., Chen, C., Wang, J. Short-term state forecasting-aided method for detection of smart grid general false data injection attacks. IEEE Transactions on Smart Grid, 2015, vol. 8, no. 4, pp. 1580–1590.

9. Shih, K.-R., Huang, S.-J. Application of a robust algorithm for dynamic state estimation of a power system. IEEE Transactions on Power Systems, 2002, vol. 17, no. 1, pp. 141–147.

10. Da Silva, A.L., Do Coutto Filho, M., Cantera, J. An efficient dynamic state estimation algorithm including bad data processing. IEEE transactions on Power Systems, 1987, vol. 2, no. 4, pp. 1050–1058.

11. Glazunova, A.M., Kolosok, I.N., S'emshchikov, E.S. Obnaruzhenie nekorreknykh dannykh pri upravlenii intellektual'noy energosistemoy metodami dinamicheskogo otsenivaniya sostoyaniya [Detection of incorrect data in the control of an intelligent energy system by methods of dynamic state estimation]. *Elektrichestvo*, 2017, no. 2, pp. 18–27.

12. Hassanzadeh, M., Evrenosoğlu, C.Y., Mili, L. A short-term nodal voltage phasor forecasting method using temporal and spatial correlation. IEEE Transactions on Power Systems, 2015, vol. 31, no. 5, pp. 3881–3890.

13. Abur, A., Exposito, A.G. Power system state estimation: theory and implementation. CRC press, 2004.

14. Zhao, J., Comer-Exposito, A., Netto, M., Mili, L., Abur, F. Power System Dynamic State Estimation: Motivations, Definitions, Methodologies, and Future Work. IEEE Transactions on Power Systems, 2019, vol. 34, no. 4, pp. 3188–3198. DOI: 10.1109/TPWRS.2019.2894769.

15. Shirman, Ya.D. *Radioelektronnyye sistemy: Osnovy postroeniya i teoriya* [Electronic systems: Basics of construction and theory]. Moscow: Radiotekhnika, 2007. 512 p.

16. Kulikov, A.L. *Tsifrovoe distantsionnoe opredelenie povrezhdeniy LEP* [Digital remote detection of power line damage]. N.Novgorod: Izdatel'stvo VVAGS, 2006. 315 p.

17. Kulikov, A.L., Lukicheva, I.A. Primenenie mnogomodel'nogo podkhoda dlya otsenki chastoty elektricheskoy seti [Application of a multi-model approach for frequency estimation in an electrical network]. *Sbornik trudov XLVIII Mezhdunarodnoy nauchno-prakticheskoy konferentsii s elementami nauchnoy shkoly «Fedorovskie chteniya – 2018»* [Proceedings of research papers of international scientific conference with scholarly traditions “Fedorov’s readings”]. Moscow, 2018, pp. 259–265.

18. Mohammad, H., Evrenosoğlu, C.Y. Power system state forecasting using regression analysis. IEEE Power and Energy Society General Meeting. 2012.

19. Sahoo, Prasanna. Probability and mathematical statistics. University of Louisville, 2013.

20. Pel, Y., Biswas, S., Fussell, D.S., Pingali, K. An elementary introduction to kalman filtering. Communications of the ACM 62.11. 2019, pp. 122–133.

21. Yizheng, Liao, Weng, Yang, Liu, Guangyi, Rajagopal, Ram. Urban mv and lv distribution grid topology estimation via group lasso. IEEE Transactions on Power Systems 34.1. 2018, pp. 12–27.

22. Meliopoulos, A., Madani, V., Novosel, D., Cokkinides, G., Alaileh, R., Fardaneshet, B. Synchrophasor measurement accuracy characterization. North American Synchro Phasor Initiative Performance & Standards Task Team (Consortium for Electric Reliability Technology Solutions). 2007, vol. 10.