

Методы прогнозирования параметров режима электроэнергетических систем для целей мониторинга и управления¹

ГАММ А.З., ГЛАЗУНОВА А.М., ГРИШИН Ю.А., КУРБАЦКИЙ В.Г.,
СИДОРОВ Д.Н., СПИРЯЕВ В.А., ТОМИН Н.В.

Для краткосрочного прогнозирования переменных предстоящего режима ЭЭС предложены подходы с использованием динамического оценивания состояния на базе фильтра Калмана и с применением современных нейросетевых технологий и методов нелинейной оптимизации. Для повышения точности краткосрочного прогнозирования разработан подход, предусматривающий совместное использование нейросетевых технологий и преобразования Гильберта–Хуанга.

Ключевые слова: энергосистема, режим, прогнозирование, оценивание состояния, фильтр Калмана, искусственная нейронная сеть, преобразование Гильберта–Хуанга

Повышение эффективности оперативного и противоаварийного управления электроэнергетическими системами (ЭЭС) во многом зависит от системы широкомасштабного мониторинга и прогнозирования режимов ЭЭС [1, 2].

В современных системах мониторинга режима крайне важной является задача краткосрочного прогнозирования параметров предстоящего режима ЭЭС. Прогноз компонент вектора состояния, представляющего собой массив модулей и фаз напряжений, позволит в дальнейшем вычислить с некоторым упреждением параметры режима ЭЭС. Прогноз перетоков активной мощности обеспечивает оценку запасов пропускных способностей связей в предстоящем режиме для сохранения устойчивости по слабым связям внутренних и внешних сечений ЭЭС с помощью выдачи соответствующих управляющих воздействий на регулирующие станции и энергоблоки [3].

Краткосрочное прогнозирование параметров режима может осуществляться как с помощью динамического оценивания состояния (ОС) на базе фильтра Калмана, так и с привлечением современных статистических методов анализа временных рядов и регрессионных моделей, а также новых информационных технологий, в первую очередь технологий искусственного интеллекта (ТИИ).

Approaches are proposed for short-term prediction of the variables of the forthcoming operating mode of an electric power system by dynamically estimating its state on the basis of Kalman's filter with the use of modern neural-network technologies and nonlinear optimization methods. To achieve more accurate short-term prediction, an approach based on a combined use of neural-network technologies and Hilbert-Huang transform is developed.

Key words: power system, operating mode, prediction, state estimation, Kalman's filter, artificial neural network, Hilbert-Huang transform

Для прогнозирования слабоизменчивых компонент вектора состояния было использовано динамическое ОС на базе фильтра Калмана. Для прогнозирования резкоизменчивых реализаций перетоков активной мощности применяется аппарат на основе новых информационных технологий.

Прогнозирование компонент вектора состояния на базе динамического оценивания состояния. Прогнозирование компонент вектора состояния на короткий срок времени выполняется с помощью динамического ОС. Время упреждения может быть от нескольких секунд (интервал между получением данных измерений (среза) в момент времени k и в момент времени $k+1$) до 1 мин. Срез – это вектор измеренных значений параметров режима ЭЭС в определенный момент времени. Такая информация в диспетчерский пункт поступает с помощью SCADA-системы (the supervisory control and data acquisition) и от регистраторов комплексных величин (PMU – Phasor Measurement Units) [4].

Все параметры режима вычисляются через вектор состояния $x=(\delta,U)$. Прогнозирование всех компонент вектора состояния на один ($k+1$) или несколько моментов времени ($k+m$) вперед позволяет вычислить оценки и их точность для всех параметров режима с таким же временем упреждения.

Для прогнозирования компонент вектора состояния используются алгоритмы динамического ОС, построенные на базе фильтра Калмана [5].

Оценивание состояния. Процедура ОС необходима для получения параметров режима ЭЭС. Возможно статическое и динамическое ОС режима

¹Работа выполнена при поддержке ведущей научной школы (грант НШ-4633.2010.8) и РФФИ (грант № 09-08-91330 ННИО а, № 09-01-00377) и в рамках международного проекта ICOEUR (см. «Электричество», 2011, № 4).

ЭЭС [6]. Статическое ОС выполняется для данных одного среза и не учитывает динамику процесса.

При решении задачи ОС вводится понятие вектора состояния x размерностью $2n-1$ (где n – число узлов расчетной схемы), включающего модули U и фазовые углы напряжений δ , кроме фиксированной фазы базисного узла. Такой вектор состояния однозначно определяет все остальные параметры режима. В качестве уравнений установившегося режима используются явные зависимости измеренных y и неизмеренных z переменных от x :

$$y = y(x); \quad (1)$$

$$z = z(x). \quad (2)$$

Уравнения (1) используются для определения компонент вектора состояния x по измеренным переменным, и задача ОС сводится к минимизации критерия:

$$J(x) = (\bar{y} - y(x))^T R_y^{-1} (\bar{y} - y(x)), \quad (3)$$

где R_y – ковариационная матрица ошибок дисперсий.

Затем по (2) вычисляются оценки неизмеренных переменных.

В качестве измерений при ОС ЭЭС в основном используются измерения, получаемые от SCADA и PMU: U_i – модули напряжений; P_{Gi} , Q_{Gi} – генерации активных и реактивных мощностей в узлах; P_{ni} , Q_{ni} – нагрузки активных и реактивных мощностей в узлах; P_{ij} , Q_{ij} – перетоки мощностей в трансформаторах и линиях; δ_i – фазы напряжений в тех узлах схемы, где установлены PMU; I_{ij} – модули токов в линиях, инцидентных этим узлам; ϕ_{ij} – угол между током и напряжением.

Динамическое ОС позволяет учесть взаимосвязь между изменяющимися во времени параметрами режима. Для динамического ОС применяется фильтр Калмана, который дает оптимальную оценку состояния ЭЭС в реальном времени, основываясь на измерениях, содержащих погрешности.

Модель шума измерения. Измерения, поступающие от SCADA системы и от PMU, представляют собой сумму значений истинной величины и нормально распределенной помехи:

$$y = y_{\text{ист}} + \xi_y, \quad \xi_y \in N(0, \sigma_y^2), \quad (4)$$

где σ_y^2 – дисперсия ошибок измерений.

Разница между двумя видами измерений заключается в их точности. Для данных PMU дисперсия ошибки меньше, чем для измерений SCADA-системы [7].

Модель динамики. Используемая модель динамики во многом определяет эффективность динамического ОС. Для короткого интервала прогнозирования параметров режима используются простые модели динамики, в которых случайные колебания параметров режима представляются в виде стационарного гауссовского процесса и все изменения параметров режима рассматриваются как случайные колебания и относятся в вектор ξ_{ϕ_k} :

$$x_{k+1} = \Phi_k x_k + \xi_{\phi_k}, \quad (5)$$

где ξ_{ϕ_k} – шум модели; $M(\xi_{\phi_k}) = 0$; $\text{cov}(\xi_{\phi_k}) = M(\xi_{\phi_k} \xi_{\phi_k}^T) = \sigma_{\phi_k}^2$; $\xi_{\phi_k} \in N(0, \sigma_{\phi_k}^2)$; $\sigma_{\phi_k}^2$ – дисперсия шума модели динамики; Φ_k – матрица перехода из одного состояния ЭЭС в другое.

Для определения дисперсии шума модели динамики $\sigma_{\phi_k}^2$ составляется выборка из s строк. Каждая строка состоит из $2n-1$ элементов. В качестве элементов этой выборки используется разность между измерениями и их оценкой Δ_{kj} . Дисперсия шума модели определяется следующим образом:

$$\text{cov}(\xi_{\phi_k}) = \sigma_{\phi_{kij}}^2 = \text{cov}(\Delta_{kj}, \Delta_{kj}^T), \quad (6)$$

где недиагональные элементы полагаются равными нулю; $\Delta_{kj} = \bar{x}_j - \hat{x}_j$ – разность между j -м измерением компоненты вектора состояния и ее оценкой для k -го среза.

Упрощенная (линейная) модель (5) соответствует действительности при следующих допущениях:

зависимость вектора состояния от времени достаточно гладкая;

малый интервал упреждения.

Процессы, происходящие в ЭЭС, можно представить марковскими, т.е. оценки параметров режима в момент времени $k+1$ определяются оценками параметров режима в момент времени k и шумом. Шум в текущий момент k уже содержит статистическую информацию. Значение дисперсии шума определяется по рекуррентным соотношениям.

Фильтр Калмана является рекуррентным способом решения задачи ОС по методу наименьших квадратов. Строятся рекуррентные соотношения, в которых оценки k -го момента времени используются при получении оценок в $k+1$ момент времени.

Точность полученных значений компонент вектора состояния определяется ковариационной матрицей ошибок прогноза, которая для среза в момент времени $k+1$ вычисляется по формуле:

$$M_{k+1} = \Phi_k P_k \Phi_k^T + W_{\phi_{k+1}}, \quad (7)$$

где $W_{\phi_{k+1}}$ – матрица, состоящая из $\sigma_{\phi_{k+1}}^2$; P_k – ковариационная матрица ошибок оценивания компонент вектора состояния.

Значения элементов ковариационной матрицы шума модели определяются по выражениям:

$$\mu_{(k+1)j} = (1-\alpha)\mu_{kj} + \alpha\Delta_{(k+1)j}; \quad (8)$$

$$\sigma_{\phi_{(k+1)j}}^2 = (1-\alpha)\sigma_{\phi_{kj}}^2 + \alpha\Delta_{(k+1)j} - \mu_{(k+1)j}^2, \quad (9)$$

где α – коэффициент забывания ($0 < \alpha < 1$); μ_j – математическое ожидание.

Ковариационная матрица ошибок оценивания компонент вектора состояния вычисляется по формуле:

$$P_{k+1} = M_k K_{k+1} H_{k+1} M_k, \quad (10)$$

где K_{k+1} – коэффициент фильтрации:

$$K_{k+1} = M_k H_{k+1} (H_{k+1}^T M_k H_{k+1} + R_{k+1})^{-1}. \quad (11)$$

Целевая функция динамического ОС. Эта функция выглядит следующим образом:

$$J(x) = (\bar{y} - y(x))^T R_y^{-1} (\bar{y} - y(x)) + (\bar{x} - x)^T M^{-1} (\bar{x} - x), \quad (12)$$

где \bar{x} – измерения или псевдоизмерения компонент вектора состояния.

В задаче динамического ОС компоненты вектора состояния рассматриваются как измерения, если они измеряются, и как псевдоизмерения, если они берутся от ОС предыдущего среза. В целевой функции они представлены разными слагаемыми. В качестве весовых коэффициентов для второго слагаемого используется матрица, обратная ковариационной матрице M^{-1} , которая позволяет учесть точность оценок, полученных в предыдущие моменты времени.

Вследствие нелинейной зависимости $y(x)$ задача решается итеративно методом Ньютона. Начальными условиями для каждого цикла являются ОС системы (значения компонент вектора состояния) и величина, характеризующая ее погрешность. Такой характеристикой является ковариационная матрица. Алгоритм обрабатывает вновь поступающие значения векторов измерений, учитывая наличие погрешностей в измерениях, и уточняет начальные условия. Скорректированные начальные условия являются выходными данными фильтра. Динамическое ОС работает корректно после настройки фильтра Калмана. Под настройкой фильтра понимается стабилизация диагональных элементов ковариационной матрицы ошибок прогноза

M , при вычислении которой матрица перехода Φ принимается единичной.

Прогнозирование компонент вектора состояния рассматривается как динамическое ОС при отсутствии поступлений новых измерений (дисперсии измерений принимаются равными бесконечности).

Значения прогнозов всех компонент вектора состояния вычисляются по формуле:

$$\tilde{x}_{k+1} = \bar{x}_k + P_k M_k^{-1} \Delta \tilde{x}_k.$$

Ошибка прогнозирования на первом такте расчёта определяется следующим образом:

$$\Delta \tilde{x}_k = |\bar{x}_k| - |\hat{x}_k|,$$

где \hat{x}_k – оценка компонент вектора состояния на предыдущем срезе; \bar{x}_k – измерение на предыдущем срезе.

На следующих срезах ошибка прогноза вычисляется по формуле

$$\Delta \tilde{x}_k = |\tilde{x}_k| - |\hat{x}_k|,$$

где \tilde{x}_k – прогноз компонент вектора состояния на предыдущем срезе.

На рис. 1 показана структурная схема прогнозирования компонент вектора состояния. На первом срезе выполняется статическое ОС. На следующих m срезах происходит настройка фильтра для выполнения процедуры прогнозирования. Далее прогнозируются компоненты вектора состояния следующего среза. При необходимости вычисляются все параметры предстоящего режима, и полученная информация передается в соответствующие программы. При поступлении следующего среза запускается процедура динамического ОС. По результатам работы ОС текущего режима проводится корректировка фильтра Калмана с использованием формул (7)–(9).

Практические результаты. Исследование прогнозирования компонент вектора состояния было выполнено на 13-узловой схеме (рис 2). Множество режимов формируется изменением потребляемой мощности в нагрузочных узлах и моделированием случайной ошибки в измерениях. Ошибки моделируются с помощью датчика случайных чисел. Значения измерений вычисляются в соответствии с выражением

$$y_{\text{им}} = y_{\text{у.р}} + x_{\text{сл}} \sqrt{\sigma^2},$$

где σ^2 – дисперсия ошибок измерений; $x_{\text{сл}} \rightarrow N(0,1)$; $y_{\text{у.р}}$ – параметр установившегося режима.

Дисперсия ошибок измерений определяется качеством метрологического тракта. В данном случае

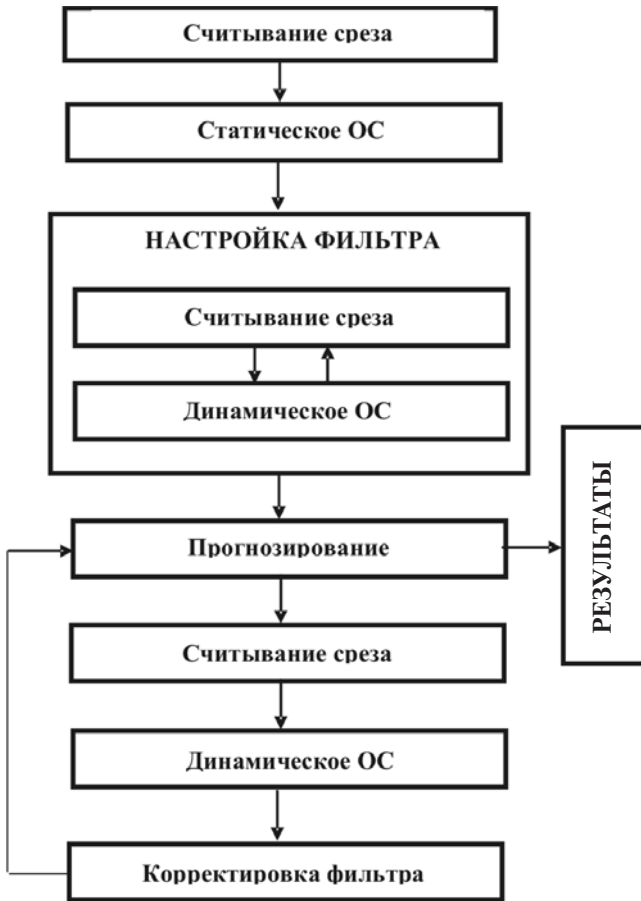


Рис. 1. Укрупненная структурная схема прогнозирования компонент вектора состояния

дисперсии ошибок измерений равны: $\sigma_U^2 = 2$ – это означает, что модуль напряжения, измеренный с помощью SCADA-системы, имеет точность $3\sqrt{2} = \pm 4,24$ кВ [7]; $\sigma_P^2 = 15$ – дисперсия активной мощности; $\sigma_Q^2 = 30$ – дисперсия реактивной мощности. В узле 11 установлено PMU, дисперсия ошибки фазы и модуля напряжения в этом узле равны $\sigma_\delta^2 = 0,01$, $\sigma_U^2 = 0,015$.

Для первого среза выполняется статическое ОС. Результаты ОС используются в качестве начальных приближений для динамического ОС. Первые несколько срезов используются для настройки фильтра. На этих срезах накапливается статистическая информация, по которой вычисляется ковариационная матрица W_Φ . При стабилизации статистик всех компонент вектора состояния фильтр Калмана считается настроенным.

Далее выполняется прогнозирование компонент вектора состояния для всех узлов в следующий момент времени. На рис. 3 показаны прогноз и измеренное (или вычисленное) значение модуля и фазы напряжения в одном из узлов ЭЭС.

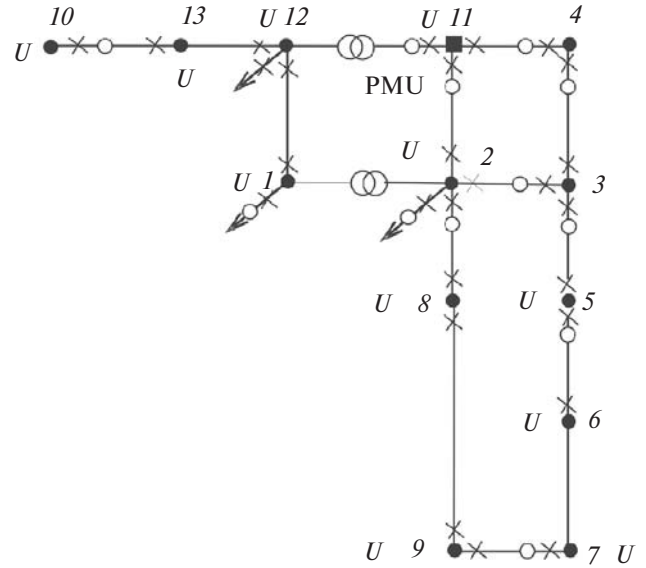


Рис. 2. Фрагмент реальной схемы

Средняя ошибка прогноза для всех узлов за 56 срезов:

Номер узла	Ошибка прогноза	
	кВ	%
1	0,2	1,4
2	0,2	1,4
3	0,2	1,0
4	0,3	1,0
5	0,3	1,5
6	0,2	1,0
7	0,3	1,5
8	0,4	2,0
9	0,2	1,0
10	0,5	2,5
11	0,1	0,7
12	0,3	2,0
13	0,4	2,8

Анализ приведенных данных показывает, что ошибка прогноза не превышает значения, которое определяется качеством метрологического тракта.

Прогнозирование параметров режима ЭЭС с использованием технологий искусственного интеллекта. Появление оригинальных подходов на базе ТИИ [10, 11] привело к разработке эффективных практических методов анализа и прогнозирования параметров режима ЭЭС.

Нейросетевое прогнозирование параметров режима ЭЭС. При прогнозировании резкоизменяющихся нестационарных реализаций параметров режима, например перетоков активной мощности, достаточно широко используются модели, сформированные на базе искусственных нейронных сетей (ИНС). Успех применения ИНС объясняется, в первую очередь, тем обстоятельством, что нейросе-

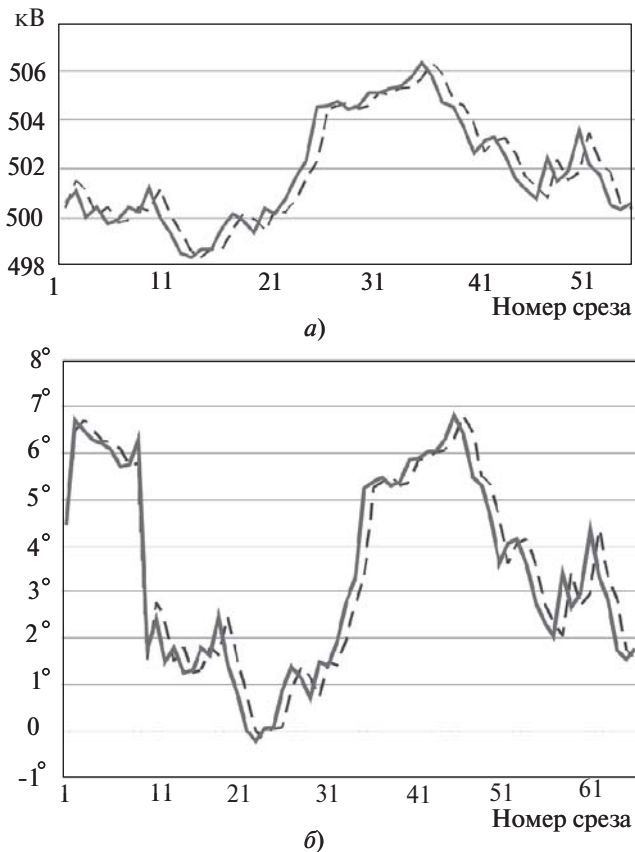


Рис. 3. Модуль (а) и фаза (б) напряжения в узле 6: - - - — прогноз

тевая архитектура (рис. 4) позволяет получать модели с «хорошими» аппроксимирующими свойствами.

Различные способы объединения нейронов между собой и организации их взаимодействия привели к созданию ИНС разных типов. Среди множества существующих структур ИНС наибольшее применение для краткосрочного прогнозирования параметров ЭЭС получили [9–11]:

многослойный персептрон (multilayer perceptron – MLP);

радиально-базисная функция (radial basis function – RBF);

обобщённо-регрессионная сеть (generalized regression neural network – GRNN).

Радиально-базисная функция. Такие нейронные сети представляют особое семейство ИНС, в котором нейроны скрытого радиального слоя реализуют радиально-базисные функции вида $\varphi(x) = \varphi(\|x - c\|)$. Полученная архитектура радиальных сетей имеет структуру, аналогичную многослойной структуре сигмоидальных сетей с одним скрытым слоем.

Обобщённо-регрессионная нейронная сеть. Представляет собой структуру, содержащую наряду со скрытым радиальным слоем и вероятностные скрытый и выходной слои. В основе таких сетей лежит метод аппроксимации плотности вероятно-

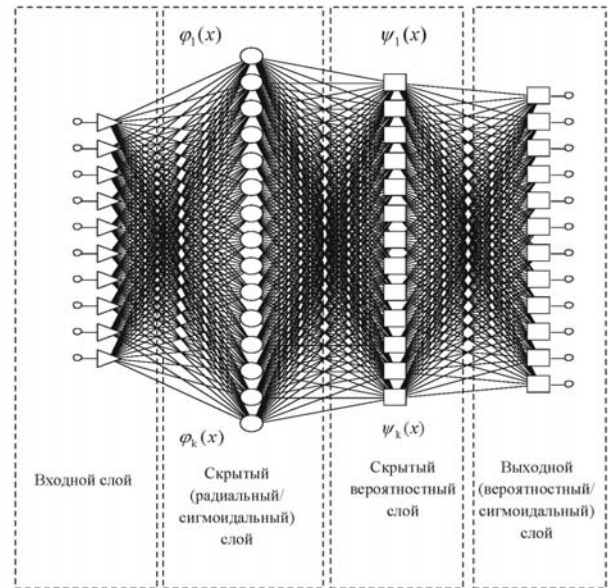


Рис. 4. Обобщённая нейросетевая структура

сти с помощью ядерных гауссовых функций $\psi(x)$ вида

$$\psi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}. \quad (14)$$

Краткосрочное прогнозирование выполнялось для телеизмеряемого межсистемного перетока активной мощности по линии 500 кВ, связывающей два крупных энергообъединения. Время упреждения принималось от 1 с до 1 мин.

На рис. 5 и в табл. 1 представлены результаты прогнозирования перетока мощности «на 60 секунд вперёд» для трехминутных интервалов с помощью традиционной модели авторегрессии и проинтегрированного скользящего среднего (АРПСС) [9] и моделей ИНС (MLP, RBF, GRNN). Результаты расчётов показали, что точность прогноза перетока мощности, выполненного в рамках моделей ИНС, практически в 2 раза выше точности прогноза, осуществлённого на базе модели АРПСС.

Для краткосрочного прогнозирования нестационарных реализаций параметров режима предложен «интеллектуальный»² подход, реализованный в «Подсистеме прогнозирования параметров режима» (рис. 6) программно-вычислительного комплекса (ПВК) «АНАПРО» [12, 13].

Использование в блоке 2 алгоритмов нелинейной оптимизации, а именно метода имитации отжига – SA³ и нейрогенетического отбора – NGIS⁴ [11], обеспечивает процедуру выбора наилучшей

²Под «интеллектуальными» понимают подход, методы, системы или комплексы, использующие технологии искусственного интеллекта.

³Simulated Annealing (SA).

⁴Neuro-Genetic Input Selection (NGIS).

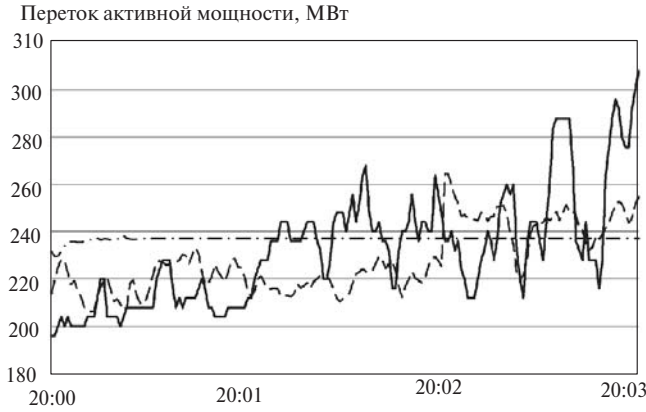


Рис. 5. Прогноз «на 60 секунд вперёд» на базе различных моделей: — фактический переток мощности; ---- — прогноз на базе модели GRNN; -.- то же модели АРПС

прогнозной модели для каждой отдельной выборки. Так, в процессе анализа обучающей выборки на базе алгоритма NGIS отдельные входные данные могут быть отброшены как менее информативные. Это метод представляет собой оптимизацию, основанную на случайных методах поиска, и соединяет в себе возможности генетического алгоритма (рис. 7) и сетей PNN/GRNN для автоматического нахождения оптимальных комбинаций входных переменных (PNN – Probably Neutral Network).

Таблица 1

Модель	Средняя ошибка прогноза за интервал, %		
	20:01	20:02	20:03
RBF	25,3	24,4	22,3
GRNN	17,7	25,1	21,3
MLP	26,1	23,1	23,1
АРПС	39,1	62,1	56,2

Использование PNN/GRNN-сетей позволяет «запоминать» наилучшие результаты, тем самым улучшая предыдущие результаты. Благодаря наличию в структуре PNN-алгоритма радиальных слоёв



Рис. 6. Подсистема прогнозирования параметров режима интеллектуального ПВК «АНАПРО»

с гауссовыми функциями удаётся обеспечить робастность к «плохим данным» во входной выборке.

Методика имитации отжига SA позволяет проанализировать свойства исходной выборки и организовать «соревновательную» систему между различными нейросетевыми прогнозными моделями, когда в процессе нелинейной оптимизации выбирается наилучшая модель прогнозирования – модель MLP (табл. 2).

Такая соревновательная процедура основана на критерии минимизации общего риска ИНС [10] $R(w)$, который определяется из следующего выражения:

$$R(w) = E_W(W) + \lambda E_c(W), \tag{15}$$

где $E_W(W)$ – стандартная мера эффективности, которая зависит как от самой сети (модели), так и от входных данных; $E_c(W)$ – штраф за сложность, зависит исключительно от самой ИНС и определяется на основе предварительных сведений о структуре модели; λ – параметр регуляризации.

В случае сложной вычислительной задачи прогнозирования (например, обучающая выборка содержит много дополнительных факторов) в основе предлагаемого подхода используется принцип ассоциативной машины (СМ – Committee Machine) [11] (рис. 8).

Таблица 2

Число этапов SA	Тип прогнозной модели	Абсолютная ошибка, МВт	Число нейронов		Мера эффективности ИНС $E_W(W)$
			входных	скрытых	
1	MLP	238,88	2	1	0,367
2	GRNN	140,59	6	37	0,366
3	GRNN	140,58	6	37	0,366
4	GRNN	140,58	6	37	0,366
5	MLP	105,53	2	6	0,268
6	RBF	43,89	6	19	0,115
7	RBF	32,46	6	22	0,082
8	RBF	28,29	6	29	0,076
9	MLP	8,71	3	1	0,022
10	MLP	6,56	3	5	0,015

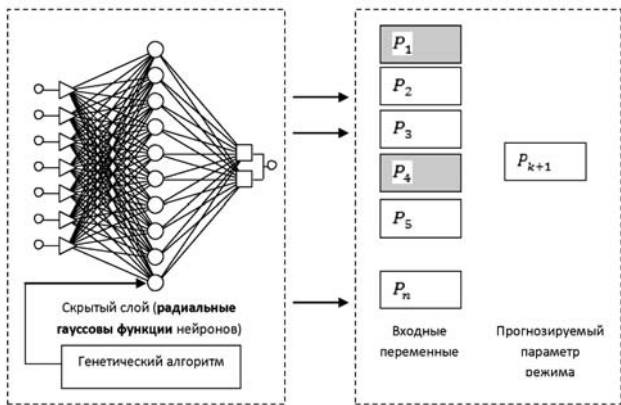


Рис. 7. Алгоритм нейрогенетического отбора

Она представляет собой нейросетевую систему, которая состоит из комбинации нейросетей-экспертов (табл. 3), позволяющих найти общее решение $y(n)$, имеющее приоритет над каждым решением отдельного эксперта $y_k(n)$.

Таблица 3

Процент примеров		Тип ИНС	Средняя ошибка, %		
тестовых	проверочных		10:00-11:00	11:00-12:00	12:00-13:00
8	8	GRNN	2,87	1,81	6,35
12	15	RBF	2,54	3,29	7,58
19	23	GRNN	2,46	3,17	7,28
4	4	RBF	3,06	2,04	7,25
12	12	RBF	2,60	3,27	7,29
8	8	RBF	2,78	2,89	8,61

Результаты вычислений свидетельствуют о том, что при различных сочетаниях обучающих и тестовой выборки при использовании СМ требуется, как правило, не более 3–6 запусков процедуры SA для формирования нейросетей-экспертов.

С использованием ПВК «АНАПРО» было осуществлено краткосрочное прогнозирование телеизмеряемого перетока мощности «на 60 секунд вперед» (рис. 9).

На рис. 9,а и в табл. 4 приведены результаты поминутного прогнозирования межсистемного перетока мощности «на 60 секунд вперед». Из представленных расчётов видно, что интеллектуальная модель позволяет снизить погрешность прогнозирования по сравнению с простым нейросетевым прогнозированием. В случае же прогноза на «1 секунду вперед» с последующей коррекцией результата ошибка прогноза значительно снижается (см. рис. 9,б и табл. 4).




Рис. 8. Структура ассоциативной машины для задачи прогнозирования

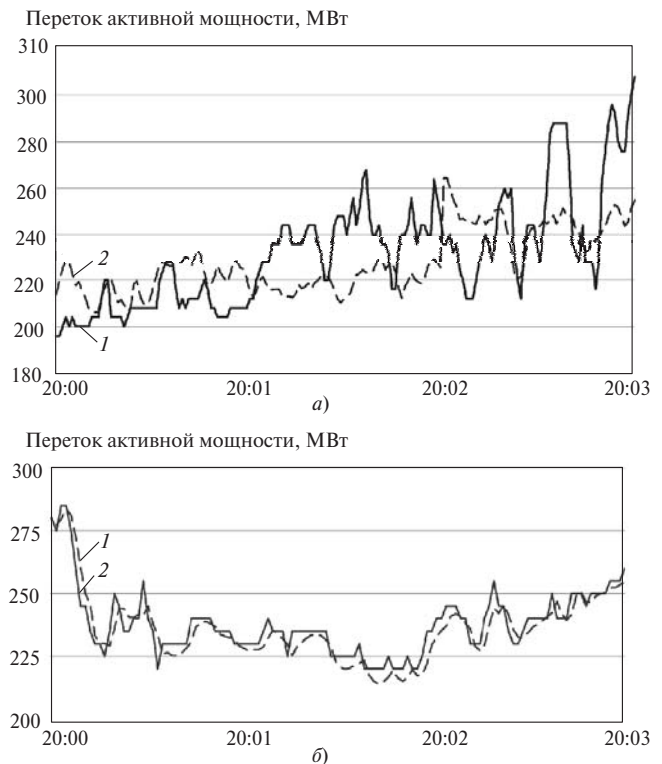


Рис. 9. Прогноз перетока активной мощности: а – «на 60 секунд вперед»; б – «на 1 секунду вперед» на базе интеллектуального подхода: 1 – фактический переток мощности; 2 – прогноз на базе интеллектуальной модели

Таблица 4

Модель	Средняя ошибка прогноза за интервал, %		
	20:00–20:01	20:01–20:02	20:02–20:03
Прогноз на «60 секунд вперед»			
ИНС типа GRNN	17,7	25,1	21,3
Интеллектуальная	16,1	21,1	18,1
Прогноз на «1 секунду вперед»			
ИНС типа MLP	10,1	9,1	–
Интеллектуальная	6,7	6,1	

Для повышения точности краткосрочного прогнозирования параметров режима в ИСЭМ СО

РАН разработан подход, предусматривающий совместное использование нейросетевых технологий и преобразования Гильберта–Хуанга (ПГХ) – гибридная модель.

В общем случае стандартное ПГХ [14] предусматривает описание исходного нестационарного ряда $x(t)$ семейством базисных функций – эмпирических мод (ЭМ) – с последующим применением к ним преобразования Гильберта.

В данном случае используется только метод разложения на ЭМ [14]. Исходная реализация $x(t)$ представляется в виде

$$x(t) = \sum_{j=1}^n c_j(t) + r_n(t) = \sum_{i=1}^q c_i(t) + \sum_{j=q+1}^p c_j(t) + \sum_{k=p+1}^n c_k(t) + r_n(t), \quad q < p < n, \quad (16)$$

где $c_i(t)$ – ЭМ, содержащие высокочастотный шум; $c_j(t)$ – ЭМ, отражающие физические свойства ряда; $c_k(t)$ и $r_n(t)$ – ЭМ, включающие трендовые несинусоидальные составляющие.

В [15] отмечается, что для большинства анализируемых нестационарных реализаций необходимое число ЭМ, как правило, не превышает 10. Каждая такая «мода» определяется как сигнал, удовлетворяющий следующим критериям [16]:

число экстремумов и число пересечений сигналом оси абсцисс на всём интервале должны быть либо равными, либо отличаться на единицу;

в любой точке «моды» среднее значение огибающих, определенных локальными максимумами и минимумами, должно быть равно нулю.


С позиции прогнозирования используемый подход предполагает исключение первых высокочастотных ЭМ из исходной реализации.

В дальнейшем по минутным значениям перетока активной мощности, взятым за период в одну неделю, для трёх видов выборок: исходная реализация; преобразованная 1-я выборка (с исключением 1-й ЭМ); преобразованная 2-я выборка (с исключением 1-й и 2-й ЭМ), были обучены ИНС типа RBF для прогноза перетока активной мощности «на 60 секунд вперёд».


Как показали экспериментальные расчёты (рис. 10, табл. 5), наилучшие результаты по точности прогноза удалось достичь при исключении из исходной реализации 1-й высокочастотной ЭМ. Более того, как видно из рис. 10, б, прогноз в этом случае более точен и для пиковых зон графика изменения перетока, т.е. нейросетевая модель, обученная на выборке с исключённой 1-й ЭМ, более адаптивно реагирует на появления пиков.

Кроме того, для дальнейшего повышения точности краткосрочного прогнозирования нестационарных параметров режима на короткие интервалы

Переток активной мощности, МВт



Переток активной мощности, МВт



Переток активной мощности, МВт




Рис. 10. Краткосрочный прогноз перетока активной мощности ЛЭП 500 кВ «на 60 секунд вперёд»: а – на базе исходной реализации; б – 1-я выборка; в – 2-я выборка: — — фактический переток мощности; - - - - прогноз (а – на базе ИНС; б, в – на базе ПГХ)

упреждения в работе предлагается использование гибридной модели.

Формирование такой гибридной модели проводится следующим образом:

на базе ПГХ нестационарный процесс раскладывается на ЭМ;

полученные значения ЭМ используются в качестве входных значений для нейросетевой модели;

с помощью алгоритмов NGIS и SA формируется нейросетевая гибридная модель, которая обучается прогнозировать соответствующие изменения параметра режима на заданный интервал упреждения.

Для представленной выборки межсистемного перетока мощности на базе ПГХ и интеллектуального нейросетевого подхода была сформирована гибридная

ная модель, осуществляющая предсказание с упреждением в 1 с.

Таблица 5

Тип выборки	Средняя ошибка прогноза за минуту, %		
	20:00–20:01	20:01–20:02	20:02–20:03
Исходная реализация	17,2	23,1	18,9
Гибридная модель – 1-я выборка	14,7	20,1	16,2
Гибридная модель – 2-я выборка	15,7	21,1	16,9

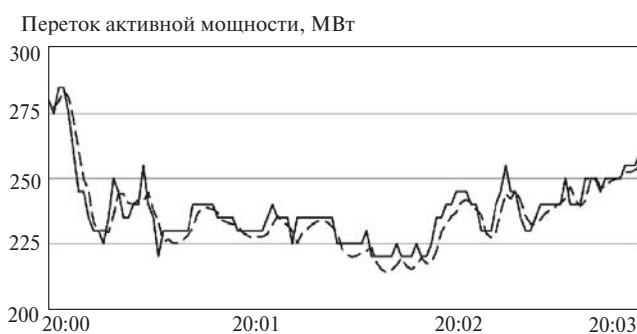


Рис. 11. Прогноз перетока активной мощности «на 1 секунду вперед»: — фактический переток мощности; - - - прогноз на базе гибридной модели

Результаты расчётов, представленные на рис. 11 и в табл. 6, свидетельствуют о том, что использование гибридной модели повышает точность прогноза.

Таблица 6

Модель	Средняя ошибка прогноза (с упреждением в 1 с) за интервал, %	
	20:00–20:01	20:01–20:02
Интеллектуальная	6,7	6,1
Гибридная	5,2	4,3

Заключение. 1. Прогнозирование компонент вектора состояния ЭЭС на короткий интервал упреждения рекомендуется осуществлять с помощью динамического оценивания состояния. Для прогнозирования резкоизменяемых параметров режима ЭЭС на более длительные интервалы упреждения целесообразно применение современных информационных технологий.

2. Динамическое оценивание состояния на базе фильтра Калмана обеспечивает прогноз компонент вектора состояния. Корректировка фильтра выполняется по рекуррентным соотношениям, что позволяет уменьшить время вычисления.

3. Измерения, полученные от РМУ, улучшают результаты прогноза. В целевой функции оценивания состояния эти данные от РМУ используются и как компоненты вектора состояния, и как точные измерения.

4. Значения компонент вектора состояния, полученные с некоторым упреждением, позволят в дальнейшем вычислить все параметры режима ЭЭС на такое же время вперед, что при достаточно высокой частоте измерений параметров режима обеспечит своевременную выработку управляющих воздействий, необходимых для эффективного управления ЭЭС.

5. Разработанный «интеллектуальный» подход для краткосрочного прогнозирования нестационарных параметров режима ЭЭС основан на базе нейросетевых технологий и методов нелинейной оптимизации.

6. Для повышения точности краткосрочного прогнозирования параметров режима предложено использовать подход, предусматривающий совместное применение нейросетевых технологий и преобразования Гильберта–Хуанга.

СПИСОК ЛИТЕРАТУРЫ

1. Kurbatsky V.G., Tomlin N.V. Artificial Intelligence Technologies for Monitoring Large Power Interconnections. – Proc. 4th Intern. Conf. «Liberalization and Modernization of Power Systems: Coordinated Monitoring and Control towards Smart Grids» (LMPS-2009), Irkutsk, 2009.
2. Voropai N.I., Kolosok I.N., Kurbatsky V.G. et al. Intelligent coordinated operation and emergency control in electric power systems. – Proc. Conf. on Control Methodologies and Technology for Energy Efficiency (CMTEE-2010), Vilamoura (Portugal), 2010.
3. Андреев А.В., Лившиц Г.Н., Машанский А.М. и др. Иерархическая система автоматического регулирования частоты и перетоков активной мощности ЕЭС России. – Электрические станции, 2010, №3.
4. Phadke A.G. Synchronized Phasor Measurements. A Historical Overview. – IEEE/PES Transmission and Distribution Conf., 2002, vol. 1.
5. Kalman R.E., Bucy R.S. New Results in Linear Filtering and Prediction Theory. – Trans. ASME Ser. D.J. Basic Eng., 1961, vol. 83.
6. Гамм А.З. Статистические методы оценивания состояния электроэнергетических систем. – М.: Наука, 1976.
7. Казаков П.Н., Могилко Р.Н., Нестеров С.А. Опыт разработки и внедрения регистраторов переходных режимов SMART-WAMS. Перспективы развития SMART-WAMS в режиме on-line. – Proc. of Conf. Monitoring of Power System Dynamics Performance, St. Petersburg, 2005.
8. Глазунова А.М., Колосок И.Н. Два подхода к использованию данных РМУ в задаче оценивания состояния электроэнергетической системы. – Методические вопросы исследования надежности больших систем энергетики. Вып. 59. Методические и практические проблемы надежности либерализованных систем энергетики. – Иркутск, 2009.
9. Боровиков В.П., Ивченко И.П. Прогнозирование в системе STATISTICA в среде Windows: Основы теории и интенсивная практика на компьютере. – М.: Финансы и статистика, 2006.

10. **Осовский С.** Нейронные сети для обработки информации. — М.: Финансы и статистика, 2004.

11. **Хайкин С.** Нейронные сети. — М.: Издат. дом «Вильямс», 2006.

12. **Курбацкий В.Г., Томин Н.В.** Использование ПВК «АНАПРО» для анализа и прогнозирования параметров режима и технологических характеристик в системах электроэнергетики. — Тр. XIII Байкальской Всерос. конф. «Информационные и математические технологии в науке и управлении», ч. I. — Иркутск: ИСЭМ СО РАН, 2008.

13. **Kurbatsky V.G., Tomin N.V.** Use of the «ANAPRO» software to analyze and forecast operating parameters and technological characteristics on the basis of macro applications. — Proc. of the Intern. Conf. «PowerTech'2009», Bucharest, 2009.

14. **Huang N.E., Zheng Shen, Long S.R. et al.** The Empirical Mode Decomposition and The Hilbert Spectrum for Non-linear and Non-stationary Time Series Analysis. — Proc. Royal Soc. London, 1998, vol. 454,

15. **Rilling G., Flandrin P., Goncalves P.** On Empirical Mode Decomposition and its Algorithms. — IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing (NSIP-03), Grado (I), 2003.

16. **Flandrin P., Rilling G., Goncalves P.** Empirical mode decomposition as a filter bank. — IEEE Sig. Proc. Lett., 2004, vol. 11, № 2.

Авторы: Гамм Александр Зельманович окончил Новосибирский электротехнический институт (НЭТИ) в 1961 г. В 1981 г. защитил в НЭТИ докторскую диссертацию «Методы анализа режимов электроэнергетических систем по данным измерений». Главный научный сотрудник ИСЭМ СО РАН.

Глазунова Анна Михайловна окончила энергетический факультет Иркутского политехнического института (ИрПИ) в 1982 г. В 2002 г. защитила кандидатскую диссертацию в ИСЭМ СО РАН «Применение методов искусственного интеллекта для решения

задач обработки измерительной информации в ЭЭС». Старший научный сотрудник ИСЭМ СО РАН.

Гришин Юрий Алексеевич окончил энергетический факультет ИрПИ в 1971 г. В 1979 г. защитил кандидатскую диссертацию в Сибирском научно-исследовательском институте электроэнергетики (СИБНИИЭ) «Исследование задачи оценивания состояния ЭЭС в реальном времени». Заместитель директора ИСЭМ СО РАН.

Курбацкий Виктор Григорьевич окончил энергетический факультет ИрПИ в 1972 г. В 1997 г. в Сибирском энергетическом институте СО РАН (г. Иркутск) защитил докторскую диссертацию «Мониторинг качества электроэнергии в электрических сетях России для выбора мероприятий по обеспечению электромагнитной совместимости». Ведущий научный сотрудник ИСЭМ СО РАН.

Сидоров Денис Николаевич окончил математический факультет Иркутского государственного университета (ИрГУ). В 1999 г. защитил кандидатскую диссертацию «Моделирование нелинейных динамических систем рядами Вольтерра: идентификация и приложения» в ИрГУ. Старший научный сотрудник ИСЭМ СО РАН.

Спиряев Вадим Александрович окончил математический факультет ИрГУ. Младший научный сотрудник ИСЭМ СО РАН.

Томин Никита Викторович окончил энергетический факультет Братского государственного университета в 2005 г. В 2007 г. в ИСЭМ СО РАН защитил кандидатскую диссертацию «Анализ и прогнозирование режимных параметров и характеристик в системах электроэнергетики на базе технологий искусственного интеллекта». Старший научный сотрудник ИСЭМ СО РАН.

* * *

**Вниманию предприятий, организаций,
НИИ, вузов России
и зарубежных фирм!**

Журнал «Электричество» предоставляет свои страницы для

- РЕКЛАМЫ ИЗДЕЛИЙ отечественных предприятий и зарубежных фирм в области энергетики, электротехники, электроники, автоматики
- ПУБЛИКАЦИИ ОБЪЯВЛЕНИЙ о научных симпозиумах, конференциях, совещаниях, семинарах
- ДРУГОЙ ИНФОРМАЦИИ, соответствующей тематике журнала

Сообщаем, что журнал поступает к зарубежным подписчикам во многих странах мира.

Напоминаем наш адрес: 101000 Москва, Главпочтамт, а/я 648.

Тел./факс (7-495)362-7485