

Задачи управления развитием крупномасштабных систем

© 2018 г. Н.И. ВОРОПАЙ, д-р техн. наук (voropai@isem.irk.ru),

Н.В. ТОМИН, канд. техн. наук (tomin@isem.irk.ru),

Д.Н. СИДОРОВ, д-р физ.-мат. наук (contact.dns@gmail.com),

В.Г. КУРБАЦКИЙ, д-р техн. наук (kurbatsky@isem.irk.ru),

Д.А. ПАНАСЕЦКИЙ, канд. техн. наук (panasetsky@gmail.com),

А.В. ЖУКОВ (zhukovalex13@gmail.com),

Д.Н. ЕФИМОВ, канд. техн. наук (efimov@isem.irk.ru),

А.Б. ОСАК (a.osak@pwr-tech.ru)

(Институт систем энергетики им. Л.А. Мелентьева СО РАН, Иркутск)

КОМПЛЕКС ИНТЕЛЛЕКТУАЛЬНЫХ СРЕДСТВ РАННЕГО ВЫЯВЛЕНИЯ И ПРЕДОТВРАЩЕНИЯ ВОЗНИКНОВЕНИЯ СИСТЕМНЫХ АВАРИЙ В ЭНЕРГООБЪЕДИНЕНИЯХ¹

Предложен комплекс интеллектуальных средств на основе интеграции методов агентного моделирования и машинного обучения для совершенствования систем защиты и противоаварийной автоматики. Изложен онлайн-подход к оценке и управлению динамической режимной надежностью электроэнергетических систем (ЭЭС) с применением потоковой модификации алгоритма случайного леса. Комплекс позволяет проводить распознавание опасных режимов сложноразветвленных ЭЭС, предотвращая риск возникновения аварийных нарушений на ранних этапах. Приводятся результаты экспериментальных испытаний на тестовых схемах IEEE.

Ключевые слова: агентное моделирование, машинное обучение, противоаварийная автоматика, электроэнергетические системы, лавина напряжения, L -индекс.

1. Введение

Становление современной теории машинного обучения, интеллектуального анализа данных и агентного моделирования предоставляет широкий арсенал эффективных численных методов мониторинга и управления большими динамическими системами. Одним из наиболее ярких примеров таких масштабных систем являются современные электроэнергетические системы (ЭЭС) со сложной многоконтурной структурой, в которых преобладают линии электропередачи средней протяженности (крупные промышленные центры, сети мегаполисов). В отличие от ЭЭС с протяженными межсистемными связями, где устойчивость параллельной работы генераторов является основным ограничивающим фактором при их функционировании, анализ сложно-

¹ Работа выполнена в рамках программы фундаментальных исследований СО РАН, рег. № АААА-А17-117030310438-1, научный проект III.17.4.2. и рег. № АААА-А17-117030310442-8, научный проект III.17.3.1.

замкнутых энергосистем в большей степени связан с устойчивостью по напряжению, которая формирует характерные ограничения в режимах работы ЭЭС. Нарушение этой устойчивости вследствие целого ряда факторов — отказов систем релейной защиты и противоаварийной автоматики (ПА), ошибок диспетчера, возникновения нерасчетных сверхнормативных возмущений и т.п. — стало основным аварийным триггером крупных системных аварий последних лет в ЭЭС Северной Америки (2003, 2006), Европы (2006), России (2005) и Индии (2012) [1].

Ситуация осложняется тем, что применение локальных (действия автоматики ограничения снижения напряжения (АОСН), форсировка возбуждения генератора) и оперативных (централизованные действия диспетчера по отключению нагрузки) противоаварийных мер при таких аварийных сценариях часто оказывались несвоевременными либо неэффективными. Более того, относительно низкий темп развития неустойчивости по напряжению теоретически дает диспетчеру возможность реализовать превентивные управляющие воздействия (УВ) для предотвращения каскадных событий. Однако практика показывает, что даже наличие нескольких минут не всегда достаточно для человека, чтобы за это время принять правильное решение. Это объясняется тем, что в аварийных и нештатных ситуациях диспетчеру ЭЭС приходится иметь дело с большими объемами данных, часто превышающих его когнитивный барьер.

Подобные критические события, а также недостатки существующей автоматики, увеличение напряженности режимов сложнзамкнутых ЭЭС и сложности управления ими привели к развитию и адаптации новых интеллектуальных алгоритмов для противодействия подобным авариям, прежде всего на базе машинного обучения (модели для оценки и управления устойчивостью ЭЭС в реальном времени [2, 3]), мультиагентных технологий (системы адаптивного управления режимами ЭЭС [4]), экспертных систем (модели интеллектуальной координации параметров режима ЭЭС [5]). Подобными “умными” моделями и системами предполагается дополнить существующие средства автоматического противоаварийного и оперативно-диспетчерского управления ЭЭС, повысив их интеллектуальный уровень. Предполагается, что интеллектуальные алгоритмы позволят автоматически координировать действия существующих устройств ПА, а также осуществлять поддержку диспетчера (к примеру, дублирование его действий по принципу «автопилота») в случае критических аварийных ситуаций, когда необходимо найти корректное решение в кратчайшие сроки. В настоящий момент эти задачи могут быть успешно реализованы в силу того, что некоторые технологии искусственного интеллекта не только показали свою эффективность при решении крайне сложных системных задач, но и в ряде конкретных направлений по отдельным возможностям превзошли самого человека (пройденный тест Тьюринга, недавние победы в сложных игровых задачах и т.д.).

В статье предлагается комплекс интеллектуальных средств, позволяющий компенсировать недостатки ряда существующих систем релейной защиты и ПА путем применения алгоритмов искусственного интеллекта (системы агентов, технология решающих деревьев) для раннего выявления и предотвращения опасных режимов сложнзамкнутых ЭЭС, прежде чем они приведут к

крупной аварии. Основная идея заключается в обучении и настройке интеллектуальных алгоритмов на своевременное распознавание характерных индикаторов устойчивости ЭЭС (коэффициенты матрицы Якоби установившегося режима, L -индекс) для реализации необходимых мероприятий по предотвращению серьезной аварии.

2. Обзор математических методов и моделей в задаче противодействия лавине напряжения

2.1. Математическая постановка задач устойчивости по напряжению в ЭЭС

Анализ механизмов развития системных аварий в ЭЭС позволяет выделить неустойчивость по напряжению в качестве одной из основных их причин [6, 7]. Потеря устойчивости в этом случае возникает, как правило, после серьезного возмущения, вследствие недостаточных локальных запасов реактивной мощности и/или снижения возможностей для ее передачи. При этом такая неустойчивость, представляя собой динамический процесс, может протекать с разной скоростью — от крайне быстрых (несколько секунд) до более медленных форм (от нескольких минут до нескольких часов). Темп потери устойчивости в общем случае зависит от целого ряда исходных физических условий системы. Как отмечено в [1], большинство системных аварий развивалось по сценарию среднесрочной неустойчивости по напряжению, когда аварийные процессы протекали относительно медленно (от одной до пяти минут).

Исходя из этого, медленные формы протекания неустойчивости по напряжению математически могут быть описаны без уравнений динамики с использованием лишь моделирования потокораспределения как основного метода исследования. В общем случае для быстроизменяющихся нагрузок устойчивость по напряжению может быть описана модифицированным якобианом установившегося режима (УР) ЭЭС. При этом линеаризованные уравнения УР в точке решения могут быть представлены в следующем виде [8]

$$(1) \quad \begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} \frac{\partial P}{\partial \delta} & \frac{\partial P}{\partial U} \\ \frac{\partial Q}{\partial \delta} & \frac{\partial Q}{\partial U} \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta U \end{bmatrix},$$

где ΔP , ΔQ , $\Delta \delta$, ΔU — соответственно векторы инкрементных изменений инъекций активной и реактивной мощностей, а также углов и напряжений в узлах ЭЭС.

В более простой интерпретации рассматриваемая устойчивость может быть определена расчетным выражением для определения напряжения в узле нагрузки (на примере двухузловой системы с бесконечным источником энергии):

$$(2) \quad U_L = \sqrt{\frac{(U_G^2 - 2Q_L X) - \sqrt{(2Q_L X - U_G^2)^2 - 4X^2(Q_L^2 - P_L^2)}}{2}},$$

где U_L и U_G — напряжения нагрузочного и генераторного узлов соответственно; P_L , Q_L — активная и реактивная мощности нагрузки соответственно; R , X — активное и реактивное сопротивления линии соответственно. Важно отметить, что выражение (2) будет также справедливо и для реальных ЭЭС со множеством источников энергии, нагрузки и линий электропередач. Исходя из (2) в общем случае предел устойчивости по напряжению будет достигнут при условии

$$(3) \quad \left| \frac{S_L}{Y_{LL}^* U_L^2} \right| = 1,$$

где Y_{LL}^+ — элементы главной диагонали матрицы проводимостей; S_L^{*+} — комплексно-сопряженная полная мощность нагрузочного узла, Y_{LL}^+ , $S_L^{*+} \in \mathbb{C}$.

На основании выражений (1) и (2) также могут быть построены специальные кривые PU и QU , которые определяют пределы по максимальной загрузке УР ЭЭС с точки зрения устойчивости по напряжению. Кривая PU дает графическое пояснение процедуры выявления предела устойчивости ЭЭС по напряжению путем постепенного утяжеления режима вплоть до предельно допустимой загруженности по передаваемой мощности через сеть. Кривая QU позволяет графически выявить чувствительность и изменение напряжения в узле по отношению к инъекциям реактивной мощности. Исходя из этого система будет устойчива по напряжению в области, где $\frac{\partial Q}{\partial U}$ положительна, в то время как предел устойчивости достигается при $\frac{\partial Q}{\partial U} = 0$. Точка, в которой достигается предел устойчивости, может быть определена как критическая точка (точка коллапса). Важно отметить, что в реальных ЭЭС точка коллапса может быть достигнута при нормальных значениях напряжений, что значительно осложняет процедуры идентификации опасных состояний.

2.2. Индикаторы устойчивости ЭЭС

Для распознавания уникальных режимных паттернов энергосистемы и управления ее устойчивостью обычно используются как методы полного моделирования, так и упрощенные приближенные методы. Первая группа методов имеет преимущества в точности анализа, так как позволяет рассмотреть все многообразие схемно-режимных ситуаций и нарушений режима. Однако значительная вычислительная сложность таких подходов существенно ограничивает их применение в режиме реального времени. Чтобы уменьшить вычислительные затраты, в большинстве систем диспетчерского управления применяются один или несколько специальных индикаторов устойчивости для количественного определения близости текущего режима ЭЭС к точке коллапса по напряжению [9]. Согласно [10, 11] все показатели устойчивости ЭЭС по напряжению можно разделить на две основные группы:

- индикаторы, полученные на основе расчета якобиана матрицы УР ЭЭС;
- индикаторы, рассчитанные на основе параметров ЭЭС.

Показатели устойчивости на основе якобиана позволяют определить точку коллапса, возможность максимальной загрузки системы и оценить запас устойчивости по напряжению. Однако эти показатели обычно требуют значительных вычислительных затрат. Меньшее время вычислений необходимо

для расчета второй группы индикаторов. Это связано с тем, что для вычисления таких показателей требуются только элементы матрицы проводимостей и некоторые режимные параметры, такие как напряжения на шинах или перетоки мощности по линиям.

При управлении в доаварийных режимах могут возникать режимные ситуации, когда скорость управления ЭЭС со стороны диспетчерского персонала оказывается недостаточной, чтобы избежать опасных состояний системы, приводящих к крупным авариям. При этом сложность заключается в том, что большинство таких состояний являются уникальными и нет универсальной методологии эффективного распознавания таких режимов в условиях резкого дефицита времени. Проблема усложняется еще и тем, что граница устойчивости энергосистемы постоянно изменяется. Более того, с переходом к рыночным отношениям многие ЭЭС часто вынуждены работать близко к границам устойчивости, когда любое возмущение, особенно сверхнормативное, может привести к существенному снижению надежности системы вплоть до ее развала. По этой причине диспетчеры должны четко чувствовать границу устойчивости во всех режимах работы ЭЭС, что очень сложно сделать без анализа, связанного с большим объемом вычислений.

В результате отсутствие процедуры «плавного» перехода от оперативного к автоматическому противоаварийному управлению (ПАУ), а также отсутствие адаптивных алгоритмов противодействия лавине напряжения значительно повышают риск крупных системных аварий, в том числе и в отечественных ЭЭС с учетом их изменяющейся структуры. Этот факт является стимулом к разработке новых противоаварийных алгоритмов на базе искусственного интеллекта.

2.3. Модели искусственного интеллекта для оценки устойчивости по напряжению

В современных условиях функционирования ЭЭС использование классических подходов к оценке и управлению устойчивостью ЭЭС (к примеру, метод функций Ляпунова, построение матриц чувствительности) в чистом виде является малоэффективным ввиду высокой вычислительной сложности. Начиная с 90-х гг. прошлого века были предложены подходы, позволяющие комбинировать традиционные методы оценки устойчивости с технологиями искусственного интеллекта, что позволило существенно ускорить и автоматизировать решение задачи управления устойчивостью ЭЭС. Подобные комбинированные подходы также относят к приближенным ввиду того, что для их обучения моделируется лишь ограниченное количество схемно-режимных ситуаций, возможных в энергосистеме (в отличие от методов полного моделирования). Однако способность таких моделей к обобщению информации и адаптации позволяет получать низкие ошибки идентификации режимов ЭЭС в темпе процесса даже в тех ситуациях, которые не были предъявлены моделям во время обучения и тестирования.

При этом анализ публикаций указывает на две основные интеллектуальные технологии — машинное обучение и мультиагентные системы, которые получили наибольшее распространение в решении этой задачи [1]. В рамках

подходов машинного обучения свою эффективность при оценки устойчивости ЭЭС показали модели искусственных нейронных сетей (ИНС) (см. [12–16] и др.), машины опорных векторов [17], модели глубокого обучения [18], решающие деревья (РД) [1, 19]. В [15] для оценивания границы динамической надежности выбран офлайн-метод инверсии ИНС с поиском единственного элемента на основе алгоритма обратного распространения ошибки. Метод инверсии ИНС позволяет найти ближайшую к текущему режиму точку на границе надежности и определить удаленность этого режима от границы. При этом ИНС обучается в режиме офлайн и используется без какой-либо коррекции для оценки близости текущего режима к границам по динамической надежности. Проверка алгоритма проводилась на 160 образцах динамически надежных и ненадежных режимов Коми ЭЭС. В [19] предложен подход для оценки устойчивости ЭЭС на базе РД, которые обучаются офлайн на основе векторных измерений. При необходимости модель РД может обновляться (дообучаться). В качестве триггера к этому могут служить существенные изменения, произошедшие в топологии схемы, в текущих состояниях генераторов или нагрузок и т.п. Такой подход продемонстрировал свою эффективность для реальной ЭЭС American Electric Power, в частности позволил предсказать неустойчивость по напряжению уже в течение первых двух секунд после аварийного нарушения. В работе [18] предлагается единый офлайн-подход для оценки устойчивости в малом ЭЭС на базе машины опорных векторов. При этом предложенная модель сравнивалась с другими обучаемыми алгоритмами: вероятностной нейронной сетью, многослойным персептроном, квантизацией векторов при обучении, k -ближайших соседей. На примере трех тестовых схем ЭЭС (New England 39, IEEE 57 и IEEE 118) подход на основе машины опорных векторов показал наибольшую точность классификации состояний ЭЭС.

Подходы, реализуемые на базе мультиагентных систем, в целом имеют единую методологию частичного [20, 21] или полноценного децентрализованного управления ЭЭС [22]. Как правило, агенты такой системы контролируют отдельные участки ЭЭС (узлы или группы узлов), отслеживая локальные параметры режима и/или характеристики оборудования. Принцип распределенного интеллекта реализуется при постоянном или периодическом обмене сообщениями между агентами для реализации заданных протоколов. При этом каждый агент преследует две цели — локальную и глобальную. Локальная состоит в поддержании контролируемых параметров на своем участке в рамках заданных граничных условий, глобальная — в предотвращении аварийного режима всей контролируемой ЭЭС. В основе знаний агентов могут использоваться различные показатели устойчивости на основе расчета якобиана матрицы УР ЭЭС [22], при определении оптимального потокораспределения [20]. Кроме того, для координации действий распределенных агентов может вводиться центральный агент [21]. В [23] предлагается дополнить мультиагентную систему технологией интеллектуального управления с прогнозирующими моделями. В этом случае для улучшения качества принимаемых решений решается оптимизационная задача для поиска наилучших действий агентов для каждой конкретной ситуации.

3. Интеллектуальная модель для предотвращения лавины напряжения

3.1. Концепция предаварийного управления

Предлагается дополнить существующие принципы управления ЭЭС способом «управления с прогнозом», который предусматривает раннее предупреждение и предотвращение опасных состояний режима и аварийных ситуаций прежде, чем они приведут к лавине напряжения [4, 6]. Таким образом, предаварийное управление представляет своеобразный «нулевой эшелон» в общей системе ПАУ и позволяет «отвести» систему от границ неустойчивости. При этом подразумевается разработка интеллектуальных средств управления, работающих в реальном времени, способных органично дополнить современные средства режимной и противоаварийной автоматики, не вступая при этом в противоречие с идеологией их работы.

Для реализации предложенной концепции авторами разработаны новые алгоритмы для предотвращения лавины напряжения на базе распределенных адаптивных моделей и моделей машинного обучения, способных эффективно предупредить и предотвратить аварийную ситуацию прежде, чем она приведет к крупной аварии и полному погашению всей ЭЭС. Разработанная в программных средах MATLAB и C++ интеллектуальная система состоит из трех основных частей (рис. 1):

1) предупредительная подсистема оценки и управления режимной надежностью ЭЭС на основе технологии решающих деревьев;

2) подсистема мультиагентной автоматики (МАО) для предотвращения лавины напряжения;

3) платформа динамического и квазидинамического моделирования поведения различных ЭЭС с целью тестирования разработанных интеллектуальных средств.




Рис. 1. Структура программной реализации интеллектуальной системы предотвращения аварий, связанных с угрозой «лавины напряжения».

3.2. Оценка и управление режимной надежностью в реальном времени

Предложен инновационный онлайн-подход для оценки и управления динамической режимной надежностью ЭЭС с применением технологии решающих деревьев, а именно потоковой модификации алгоритма случайного леса (Proximity Driven Streaming Random Forest, PDSRF) [24, 25]. Основным качественным отличием от других современных подходов является возможность алгоритма PDSRF самостоятельно и адаптивно перестраиваться в реальном времени при возникновении серьезных изменений в поступающей телеметрической информации без снижения точности при идентификации режимов ЭЭС. В основе разработанного подхода лежит классический индикатор устойчивости — L -индекс, который позволяет оценить близость надвигающегося коллапса напряжения [26]. Авторами предложено модифицировать данный подход за счет использования обучаемых онлайн-моделей на основе алгоритма PDSRF, способных «научиться» определять как глобальный L -индекс для оценки надежности всей ЭЭС, так и необходимые инъекции реактивной мощности при определении места и объема корректирующих УВ. Это позволило применить данную методологию в режиме реального времени.

В качестве базовых алгоритмов композиции в PDSRF используется Extremely Randomized Tree [27], что позволяет ускорить процесс обучения за счет использования только отдельных деревьев в режиме офлайн и обновления композиции простой заменой деревьев с низкой точностью. При этом замена происходит только в том случае, если средняя точность всего ансамбля меньше заданного порога, выбираемого из эмпирических соображений. Также ограничивается количество замен с целью лимитировать вычислительные затраты и не допустить переобучения ансамбля.

Оценка ошибки конкретного классификатора на новых примерах выполняется из следующих предположений:

- классификаторы имеют близкие ошибки на «похожих» примерах,
- функция ошибки для конкретного классификатора медленно меняется со временем $S_t = S_{t+1}$.

Это позволяет приблизить функцию ошибки с помощью взвешенного метода k ближайших соседей. В качестве обучающей выборки извлекаются примеры из буфера, а в качестве значений отклика — ошибки классификаторов на примерах буфера. Таким образом, для того чтобы найти веса для классификации конкретного примера, первоначально производится поиск похожих примеров в буфере, затем усреднение, и полученное значение определяется следующим образом:

$$(4) \quad \omega_i = \frac{1}{E_i^2(x) + \Delta},$$

где $E_i(x)$ — предполагаемая ошибка i -го классификатора ансамбля на примере x , а Δ — малый положительный параметр, который задает максимальный возможный вес. Приближение будем строить с помощью взвешенного метода k ближайших соседей. Пусть имеется буфер скользящего окна $B^q = (\dot{x}_1, \dot{y}_1), \dots, (\dot{x}_q, \dot{y}_q)$ с размером q . Задана функция расстояния $\rho(x, \dot{x})$. Для случая $x \in X$ упорядочим все примеры буфера в порядке возрастания

расстояния $\rho(x, \acute{x}_{1;x}) \leq \rho(x, \acute{x}_{2;x}) \leq \dots \leq \rho(x, \acute{x}_{q;x})$. Тогда искомая функция может быть оценена как

$$(5) \quad \tilde{E}_m^{t+1}(x) = \frac{\sum_{i=1}^k E_m^t(\acute{x}_{x,i}) \rho(x, \acute{x}_{x,i})}{\sum_{i=1}^k \rho(x, \acute{x}_{x,i})},$$

где k — количество ближайших соседей, m — номер алгоритма ансамбля.

Функция расстояния для метода k ближайших соседей может быть определена разными способами. Однако с целью сокращения вычислительной сложности целесообразно использовать внутреннюю функцию близости Random Forest Proximity. Эта функция использует структуру деревьев для получения значения близости следующим образом: если два примера попадают в одну и ту же ячейку пространства признаков, соответствующую терминальному узлу дерева, то значение увеличивается на единицу. По завершении процесса итоговая функция определяется по количеству деревьев. Такая метрика может быть определена по аналогии с KeRF [28]. Пусть для ансамбля из M деревьев имеем обучающую выборку $\mathcal{D}_n = \{(\mathbf{X}_i, Y_i)\}_{i=1}^n$ и набор независимых случайных величин $\Theta = \{\Theta_1, \dots, \Theta_M\}$, которые не зависят от $\mathcal{D}_n$ и используются в процедурах рандомизации для выбора случайного разбиения и построения случайных подвыборок (создание бутстрэпа). Тогда определим $A_n(x, \Theta_j)$ как ячейку пространства признаков, соответствующую терминалу ветви дерева, в которую попадает пример x , если дерево построено при использовании Θ_j по выборке $\mathcal{D}_n$. В этих терминах метрика близости может быть выражена как

$$(6) \quad Prox(x, u) = \frac{1}{M} \sum_{j=1}^M [x \in A_n(u, \Theta_j)].$$

Таким образом, имеем два механизма адаптации к изменениям в анализируемых данных: замена неэффективных базовых алгоритмов и адаптивное правило объединения ответов алгоритмов композиции. Предложенная подсистема состоит из двух основных моделей на базе PDSRF — локальной и глобальной. Глобальная модель на основе входных параметров режима (напряжения узлов, нагрузки, перетоки мощности и т.д.) обучается корректно идентифицировать глобальный L -индекс. В качестве основного критерия устойчивости системы был выбран L -индекс, предложенный в [7] как индикатор надвигающегося коллапса напряжения. Известно, что изменение мощности может произойти в любом из нагрузочных узлов системы, который может играть важную роль в оценки устойчивости ЭЭС. При этом эквивалентное напряжение узла j , $\dot{U}_{0j}$ будет изменяться очень незначительно, так как напряжение генератора остается практически постоянным при различных нагрузках. С учетом отмеченных эффектов был предложен локальный индикатор устойчивости системы для каждого нагрузочного узла L_j , рассчитываемый по выражению

$$(7) \quad L = \max_{j \in \alpha_L} (L_j) = \left| 1 + \frac{\dot{U}_{0j}}{\dot{U}_j} \right| = \left| \frac{\dot{S}_j^+}{\dot{Y}_{jj}^{+*} U_j^2} \right| = \frac{S_j^+}{Y_{jj}^+ U_j^2}.$$

Здесь Y_{jj}^+ – преобразованные собственные проводимости; U_j – напряжение в нагрузочном узле; S_j^+ – преобразованная комплексно-сопряженная мощность, которая может быть рассчитана по выражению

$$\dot{S}_j^+ = \dot{S}_j + \left(\sum_{j \in \alpha_L, i \neq j} \frac{\dot{Z}_{ji}^* \dot{S}_i}{\dot{Z}_{jj}^* \dot{U}_i} \right) \dot{U}_j,$$

где $\dot{Z}_{ji}^*$ и $\dot{Z}_{jj}^*$ – соответственно комплексно-сопряженные недиагональные элементы и элементы главной диагонали матрицы полных сопротивлений.

В качестве выходного сигнала глобальная модель PDSRF выдает численное значение глобального L -индекса, изменяющееся в диапазоне от 0 – режим холостого хода до 1 – коллапс напряжения. При этом выходное значение L -индекса интерпретируется как общесистемный сигнал (индикатор) режимной надежности всей ЭЭС, который подается диспетчеру, информируя последнего об общем уровне устойчивости ЭЭС («высокий», «низкий», «авария»), и позволяет предсказать (оценить) степень опасности текущего режима ЭЭС с точки зрения близости к коллапсу напряжения.

Локальная модель PDSRF, в свою очередь, обучается определять необходимые инъекции реактивной мощности по нагрузочным узлам схемы. В качестве входных значений локальной модели используются как параметры режима ЭЭС, так и расчетные значения локального L -индекса L_j в текущий момент времени. Основу обучения локальной модели PDSRF составляют результаты решения системы уравнений относительно частных производных функции суммы локальных L -индексов ($L_{\text{sum}} = L_1 + L_2 + \dots + L_m$, где m – количество нагрузочных узлов схемы) по дополнительным инъекциям реактивной мощности, ΔQ

$$(8) \quad \frac{\partial L_{\text{sum}}}{\partial \Delta Q} = \begin{bmatrix} \frac{\partial L_{\text{sum}}}{\partial \Delta Q_1} \\ \vdots \\ \frac{\partial L_{\text{sum}}}{\partial \Delta Q_m} \end{bmatrix} = \begin{bmatrix} \sum_{i \in \alpha_L, i \neq j} -\frac{1}{U_j} \frac{X_{j1}}{U_1} \frac{\mu}{\sqrt{\mu^2 + \gamma^2}} \\ \vdots \\ \sum_{i \in \alpha_L, i \neq j} -\frac{1}{U_j} \frac{X_{jm}}{U_m} \frac{\mu}{\sqrt{\mu^2 + \gamma^2}} \end{bmatrix} = 0,$$

где

$$\mu = \sum_{i \in \alpha_L, i \neq j} \frac{(Q_i + \Delta Q_i) X_{ji}}{U_i}; \quad \gamma = \sum_{i \in \alpha_L, i \neq j} \frac{-P_i X_{ji}}{U_i}.$$

Исходя из (8) ЭЭС будет работать в оптимальном УР при минимальном значении суммы локальных L -индексов, L_{sum} . В результате обученная локальная модель PDSRF способна определять значения дополнительных инъекций реактивной мощности для осуществления необходимых корректирующих и/или превентивных УВ в режиме онлайн.

Важно отметить, что выходные сигналы разработанной подсистемы могут поступать как диспетчеру, так и непосредственно в локальные автоматики

управления напряжением и реактивной мощностью (к примеру, классическая АОСН или децентрализованная МАА). Взаимодействия с локальными автоматами позволяют при необходимости скорректировать действия последних, т.к. именно они обеспечивают своевременное автоматическое включение источников реактивной мощности (ИРМ) для регулирования напряжения. В рамках предлагаемой интеллектуальной системы реализована связка двух подсистем PDSRF + МАА для эффективного предотвращения лавины напряжения. Связка PDSRF + МАА позволяет реализовать специальный протокол по достоверизации УВ при управлении ИРМ с учетом не только локальной информации агентов, но и результатов глобального мониторинга текущего режима на основе модели PDSRF. Это позволяет провести автоматическую адаптацию критериев управления внутри МАА, повышая тем самым эффективность предотвращения лавины напряжения.

3.3. Децентрализованная мультиагентная автоматика

Предложена децентрализованная адаптивная автоматика предотвращения лавины напряжения, которая строится на базе мультиагентного подхода. Разработанная МАА, реализованная в программных средах MATLAB (квазидинамическое моделирование) и Java Agent Development Framework (JADE) (динамическое моделирование), осуществляет управление реактивной мощностью, предотвращает аварийное отключение генераторов и сохраняет напряжение на шинах нагрузки в допустимых пределах. В ее основу легли децентрализованные алгоритмы адаптивного управления ИРМ, где каждый источник (агент) является автономной единицей, обеспечивающей глобальную цель — предотвращение коллапса напряжений не в ущерб своим локальным интересам — предотвращение локальной перегрузки контролируемого ИРМ [4, 22].

При этом все агенты разделены на две группы: агенты нагрузки и агенты генерации. Любой агент в любой момент времени имеет доступ к следующему набору локальных данных:

- 1) локальные параметры режима (первичное и вторичное напряжения, потоки активной мощности и т.д.);
- 2) характеристики режима работы оборудования (напряжения на выводах генератора, номер отпайки устройства регулирования напряжения под нагрузкой трансформатора, ток возбуждения генератора, сигналы фиксации отключения устройств и т.д.).

Для реализации МАА энергосистема должна быть предварительно разбита на подсистемы с минимальной взаимной связностью. Декомпозиция позволяет упростить задачу управления, минимизировать объем передаваемых данных и финансовые затраты на телемеханизацию, а также учесть структурные особенности отдельных подсистем. Для реализации свойств адаптивности агенты МАА обладают определенным набором знаний о подсистеме, в которой они установлены. Это позволяет выбирать более эффективные УВ, исходя из текущих схемно-режимных условий. Знания агента о подсистеме предлагается сформировать в виде базы знаний с использованием подхода,

основанного на анализе чувствительности коэффициентов матрицы Якоби уравнений УР, полученных согласно выражению (1).

Если полагать неизменными инъекции активной мощности ($\Delta P = 0$), то коэффициенты чувствительности, определяющие влияние изменения инъекций реактивной мощности на уровни напряжений в узлах ЭЭС, определяются как

$$(9) \quad \begin{aligned} \frac{\Delta Q}{\Delta U} &= \frac{\partial Q}{\partial U} - \frac{\partial Q}{\partial \delta} \left(\frac{\partial P}{\partial \delta} \right)^{-1} \frac{\partial P}{\partial U}, \\ \frac{\Delta U}{\Delta Q} &= \left(\frac{\Delta Q}{\Delta U} \right)^{-1}. \end{aligned}$$

Процесс формирования базы знаний агента заключается в нахождении коэффициентов чувствительности для различных вариантов топологии защищаемой подсистемы. Анализ режимов (нахождение коэффициентов чувствительности) выполняется единожды, а количество получаемой в результате анализа информации может с достаточной для решаемой задачи скоростью обрабатываться любым современным контроллером. Полученная в результате анализа база данных должна быть передана всем агентам внутри защищаемой подсистемы.

4. Вычислительный эксперимент

Эффективность разработанной системы проверялась на следующих схемах: IEEE RTS-96 (модифицированная 53-узловая схема) и IEEE 118 (118-узловая схема). Все расчеты проводились на двух рабочих станциях с процессорами Intel(R) Core(TM) i7-4930K @ 3.40 GHz 3.30 GHz. Тестовые испытания были реализованы в разработанной платформе моделирования в среде MATLAB/PSAT с привлечением следующих моделей имитации поведения ЭЭС: (1) динамической модели, позволяющей выполнять классическое исследование электромеханического движения ЭЭС с использованием системы дифференциально-алгебраических уравнений и (2) квазидинамической модели, обеспечивающей точность моделирования динамики, достаточную для исследования устойчивости по напряжению, токовой перегрузки связей, алгоритмов локальных устройств автоматики и т.д. (рис. 2).

В основной алгоритм процедуры квазидинамики был также включен сценарий, предусматривающий резкое увеличение мощности нагрузки на шинах 15, 19 и 38 (рис. 2), что в реальных ЭЭС может соответствовать подключению крупных потребителей в схему. Реализация такого сценария позволила смоделировать так называемый эффект «изменение концепции» (от англ. “concept drift”) [25], под которым понимается непредсказуемое изменение входных данных алгоритма. Для ЭЭС это могут быть любые новые схемно-режимные ситуации, к примеру резкий скачок нагрузки, отключение нескольких генераторов и пр., что изначально не было включено в обучающие и тестовые выборки. Анализ показал, что многие ранее предложенные методы для анализа надежности предусматривают периодическое дообучение модели при возникновении новых ситуаций [1]. Однако предложенная модель на основе




Рис. 2. *a*) Квазидинамическое моделирование коллапса напряжения тестовой схемы IEEE 118.

PDSRF при необходимости способна обновляться самостоятельно в режиме онлайн, чтобы адаптивно перестроиться, не снижая точность идентификации состояний ЭЭС.

Тестовые испытания интеллектуальной подсистемы оценки и управления режимной надежностью показали, что разработанный онлайн-подход на базе метода PDSRF позволяет с высокой точностью идентифицировать общесистемный уровень режимной надежности тестовой ЭЭС. Так точность идентификации режима для схемы IEEE 118 составила 97,24% (табл. 1), что примерно на 10% выше точности других известных интеллектуальных подходов.

Таблица 1. Эффективность алгоритмов машинного обучения при идентификации общего состояния тестовой схемы IEEE 118 на основе оценки глобального L -индекса, %

Алгоритм	Точность	Индекс Каппа
Глобальный PDSRF	97,24	95,30
Машина опорных векторов	81,54	64,92
Случайный лес	96,01	93,24
Градиентный бустинг решающих деревьев	93,64	89,41
Нейросеть экстремального обучения	80,80	6,08




Рис. 2. б) Изменение напряжений узлов 15, 19, 39 с резким возрастанием мощности нагрузки.

Разработанный программный прототип позволяет также локализовать в текущий момент времени «критические» нагрузочные узлы, где значения локального L -индекса выше относительно остальных узлов схемы (см. рис. 3, а).

Таблица 2. Эффективность алгоритмов машинного обучения при определении дополнительных объемов инъекций ΔQ_i для нагрузочных узлов тестовой схемы IEEE 118 на основе оценки локальных L -индексов

Алгоритм	Среднеквадр. ошибка, RMSE	Абсолют. средняя ошибка, MAE	Время обучения, с	Время тестирования, с
Локальный PDSRF	0,1299	0,1116	4,812	0,00149
Машина опорных векторов	0,1498	0,1254	3,441	0,00167
Случайный лес	0,1502	0,1271	0,811	0,00153
Градиентный бустинг решающих деревьев	0,1463	0,1234	4,671	0,00282
Нейросеть экстремального обучения	0,1517	0,1282	0,021	0,00153





Рис. 3. *a*) Значения локальных L -индексов по нагрузочным узлам IEEE 118 для одного из рассчитанных УР и *б*) кривые суммы локальных L -индексов до и после корректирующих УВ для схемы IEEE 118.




Рис. 4. Осциллограмма для тестового возмущения в схеме IEEE RTS-96 (динамическое моделирование) в случае действия МАА: отключение трансформатора 101-208 в момент времени $t = 10$ с.




Рис. 5. Результаты квазидинамического моделирования на схеме IEEE 118. Сравнение перегрузки агрегатов при различных подходах.

Кроме того, расчеты показали, что предложенный онлайн-подход на базе PDSRF также обеспечивает низкие ошибки (среднеквадратичная ошибка в пределах 11% для IEEE 118) и высокую скорость нахождения решения (несколько сотых долей секунды для каждого УР IEEE 118 по сравнению с 30–40 мин в рамках традиционного подхода) при определении объемов дополнительных инъекций реактивной мощности (табл. 2). Этот факт позволяет эффективно использовать предупредительную подсистему мониторинга для управления режимной надежностью для ЭЭС большой размерности в реальном времени. Полученные значения дополнительных инъекций были использованы для компенсации реактивной мощности с помощью ИРМ. В результате удалось добиться снижения суммы L -индексов по нагрузочным узлам, увеличение которых свидетельствует о все большей близости системы к коллапсу напряжения, прежде всего для утяжеленных и опасных режимов схемы IEEE 118 (рис. 3,б).

Испытания МАО, выполненные для схемы IEEE RTS-96, показали, что координация локальных устройств за счет реализации дополнительных УВ от предложенной МАО позволяет эффективно бороться с перегрузкой оборудования и, как следствие, с лавиной напряжения. При этом если противодействовать перегрузке генераторов с использованием лишь локальных принципов традиционного ПАУ, то будет достаточно сложно гарантировать своевременную ликвидацию аварийной ситуации. Однако децентрализованная координация локальных устройств ПА посредством МАО позволила в тестовой схеме IEEE RTS-96 предотвратить лавину напряжения в подсистеме при минимуме затрат (рис. 4). В частности, там, где локальная автоматика не смогла справиться с ситуацией, МАО предотвратила лавину напряжения без реализации отключения нагрузки, а лишь за счет координации ИРМ.

Работоспособность МАО была также проверена на примере схемы IEEE 118 в рамках квазидинамического моделирования последовательно-

сти УР (рис. 5). Проведенные испытания показали, что вероятность каскадного отключения в случае использования МАА снижается, так как за счет перераспределения реактивной мощности загрузка генераторов будет осуществляться более равномерно по сравнению с ситуацией, когда МАА вообще отсутствует. Результаты тестовых расчетов позволяют говорить о том, что предложенная МАА обеспечивает возможность строгой фиксации момента необходимости перехода от задачи вторичного регулирования к задаче ПАУ, исключая тем самым человеческий фактор и обеспечивая непрерывность процессов оперативного и автоматического ПАУ.

5. Заключение

Разработанный комплекс интеллектуальных средств позволяет компенсировать выявленные недостатки ряда существующих систем защиты и ПА путем применения различных алгоритмов искусственного интеллекта (системы агентов, технологии решающих деревьев) для раннего выявления и предотвращения опасных режимов сложнзамкнутых ЭЭС, прежде чем они приведут к крупной аварии. Предложенная в статье интеллектуальная система для раннего предупреждения и предотвращения тяжелых системных аварий в ЭЭС продемонстрировала свою высокую эффективность в решении основных задач, заложенных в реализованных алгоритмах.

СПИСОК ЛИТЕРАТУРЫ

1. Воронай Н.И., Томин Н.В., Курбацкий В.Г. и др. Комплекс интеллектуальных средств для предотвращения крупных аварий в электроэнергетических системах. Новосибирск: Наука, 2016.
2. Воронай Н.И., Саратова Н.Е. Анализ статистики отказов РЗА на микропроцессорной базе с точки зрения их учета при моделировании каскадных аварий // Проблемы энергетики. 2008. № 11/12 (1). С. 66–71.
3. Воронай Н.И. Снижение рисков каскадных аварий в электроэнергетических системах. Новосибирск: Изд-во СО РАН, 2011.
4. IEEE PES CAMS Task Force on Understanding, Prediction, Mitigation and Restoration of Cascading Failures “Initial Review of Methods for Cascading Failure Analysis in Electric Power Transmission Systems” // Proc. IEEE PES General Meeting, Pittsburgh, PA USA, July, 2008.
5. Negnevitsky M. An Expert System Application for Clearing Overloads // Int. J. Power Energy Syst. 1995. V. 15. No. 1. P. 9–13.
6. Барканс Е., Жалостиба Д. Защита от развалов и самовосстановление энергосистем. Чебоксары: РИЦ «СРЗАУ», 2014.
7. Kessel P., Glavitsch H. Estimating the Voltage Stability of a Power System // IEEE Trans. Power Delivery. 1986. V. 1. No. 3. P. 346–354.
8. Войтов О.Н., Воронай Н.И., Гамм А.З. и др. Анализ неоднородностей электроэнергетических систем. Новосибирск: Наука, 1999.
9. Goh H. Comparative Study of Different Kalman Filter Implementations in Power System Stability // Amer. J. Appl. Sci. 2014. V. 11. No. 8. P. 1379–1390.
10. Karbalaee F., Soleymani H., Afsharnia S. A Comparison of Voltage Collapse Proximity Indicators // IPEC, 2010 Conf. Proc. 2010. P. 429–432.

11. *Sayed Shah D.M.* Voltage Stability in Electric Power System: A Practical Introduction. Berlin: Logos Verlag GmbH, 2015.
12. *Kurbatsky V.G., Sidorov D.N., Spiryaev V.A., Tomin N.V.* The Hybrid Model Based on Hilbert-Huang Transform and Neural Networks for Forecasting of Short-Term Operation Conditions of Power Systems // Proc. IEEE PES Trondheim PowerTech. Trondheim. 2011. P. 1–7.
13. *Zhukov A., Tomin N., Sidorov D., Panasetsky D., Spirayev V.* A Hybrid Artificial Neural Network for Voltage Security Evaluation in a Power System // Proc. 2015 Int. Youth Con. Energy (IYCE). Pisa, 2015. P. 1–8.
14. *Kurbatsky V., Tomin N., Sidorov D., Spiryaev V.* Application of Two Stages Adaptive Neural Network Approach for Short-Term Forecast of Electric Power Systems // Proc. 10 Int. Conf. Environ. Electr. Engineer. Rome. 2011. P. 1–4.
15. *Манов Н.С., Хохлов М.В., Чукреев Ю.Я. и др.* Методы и модели исследования надежности электроэнергетических систем. Сыктывкар: Изд-во Коми научный центр УрО РАН, 2010.
16. *Курбацкий В.Г., Сидоров Д.Н., Спиряев В.А., Томин Н.В.* Прогнозирование нестационарных временных рядов на основе преобразования Гильберта–Хуанга и машинного обучения // АИТ. 2014. № 5. С. 143–158.
Kurbatskii V.G., Sidorov D.N., Spiryaev V.A., Tomin N.V. On the Neural Network Approach for Forecasting of Nonstationary Time Series on the Basis of the Hilbert–Huang Transform // Autom. Remote Control. 2011. V. 72. No. 7. P. 1405–1414.
17. *Kalyani S., Shanti Swarup K.* Design of Pattern Recognition System for Static Security Assessment and Classification // Patt. Anal. Appl. 2012. V. 15. P. 299–311.
18. *Jothinathan K., Ganapathy S.* Transient Security Assessment in Power Systems Using Deep Neural Network // Int. J. Appl. Engin. Res. 2012. V. 10. No. 15. P. 787–790.
19. *Diao R., Sun K., Vittal V., et al.* Decision Tree-Based Online Voltage Security Assessment Using PMU Measurements // IEEE Trans. Power Syst. 2009. V. 24. No. 2. P. 832–839.
20. *Архипов И.Л., Иванов А.М., Холкин Д.В. и др.* Мультиагентная система управления напряжением и реактивной мощностью // Тр. 22-й конф. «Релейная защита и автоматика энергосистем». Москва. 2014. С. 243–252.
21. *Belkacemi R., Babalola S., Zarrabian A.* Experimental Implementation of Multi-Agent System Algorithm to Prevent Cascading Failure after $N - 1 - 1$ Contingency in Smart Grid Systems // IEEE Power & Energy Society General Meeting, Denver, CO. 2015. P. 1–5.
22. *Панасецкий Д.А.* Совершенствование структуры и алгоритмов противоаварийного управления ЭЭС для предотвращения лавины напряжения и каскадного отключения линий // Дис. ... канд. техн. наук: 05.14.02; Иркутск: ИСЭМ СО РАН, 2015. 192 с.
23. *Negenborn R.R., De Schutter B., Hellendoorn J.* Multi-agent Model Predictive Control for Transportation Networks: Serial Versus Parallel Schemes // Engineer. Appl. Artif. Intelligence. 2008. V. 21. P. 353–366.
24. *Жуков А.В., Сидоров Д.Н.* Модификация алгоритма случайного леса для классификации нестационарных потоковых данных // Вестн. ЮУрГУ. Сер. Матем. моделирование и программирование. 2016. Т. 9. № 4. С. 86–95.
25. *Zhukov A.V., Sidorov D.N., Foley A.M.* Random Forest Based Approach for Concept Drift Handling // Commun. Comput. Inform. Sci. 2017. V. 661. P. 69–77.

26. *Воропай Н.И., Негневицкий М., Томин Н.В. и др.* Интеллектуальная система для предотвращения крупных аварий в энергосистемах // Электричество. 2014. № 8. С. 1–7.
27. *Geurts P., Ernst D., Wehenkel L.* Extremely Randomized Trees // Machine Learning. 2006. V. 63. No. 1. P. 3–42.
28. *Scornet E.* Random Forests and Kernel Methods // IEEE Trans. Inform. Theory. 2016. V. 62. No. 3. P. 1485–1500.
29. *Kundur P.* Power System Stability and Control. N.Y.: McGraw Hill, 1994.

Статья представлена к публикации членом редколлегии А.И. Михальским.

Поступила в редакцию 09.11.2017