

НАВИГАТОР ДИСПЕТЧЕРА СОВРЕМЕННЫЕ МОДЕЛИ ОПЕРАТИВНОГО ПРОГНОЗА НАГРУЗКИ РАСПРЕДЕЛИТЕЛЬНЫХ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ

**Н.Д. АРАПОВ, Д.А. БЕЛЯКОВ, И.В. МОСКОВОЙ (ООО “Прикладные программы”),
С.Н. РЫКОВАНОВ, М.А. ХОЗЯИНОВ (ООО “Систел”)**

Статья является продолжением серии статей [1, 2], посвященных программному комплексу “Навигатор диспетчера”, разработанному для непрерывного, адаптивного и оптимального управления режимами распределительной электрической сети в ответ на внутренние и внешние воздействия. В статье рассмотрено одно из решений задачи оперативного прогноза нагрузки.

Ключевые слова: *распределительная электрическая сеть; трансформаторная подстанция; навигатор диспетчера; адаптивный оптимальный режим; рекомендации; оперативный прогноз нагрузки; модель прогноза на основе нейронной сети.*

ВВЕДЕНИЕ

Программный комплекс “Навигатор диспетчера”, далее в тексте Навигатор, принадлежит к классу ADMS систем, но отличается от традиционной ADMS наличием возможности автоматической навигации диспетчера по управлению распределительной сетью по мере изменения нагрузки и топологии сети. Навигатор в режиме реального времени автоматически выдает рекомендации по поддержанию надежного и оптимального состояния, информируя диспетчера о текущем режиме сети: аварийном; послеаварийном; вынужденном; нормальном. Рекомендации представляют собой перечни действий оперативно-диспетчерской группы по определению места повреждения, по изолированию поврежденного оборудования, по восстановлению питания потребителей, по восстановлению нормальной схемы, схемы до аварии/инцидента, по вводу в допуск напряжений, по устранению перегрузок, по снижению потерь электроэнергии, по симметрированию нагрузки и т.п.

Рекомендации охватывают временной горизонт до 120 минут, на котором производится оперативное планирование работы сети. Все будущие состояния сети на любой момент времени горизонта должны проверяться на допустимость по надежности, режиму, селективности, чувствительности защит и т.д. Поэтому для каждого момента времени изменения топологии или положений регуляторов оборудования сети рекомендации требуется прогноз режима,

выполняемый в реальном времени и обеспечивающий требуемую точность на всем оперативном горизонте. Точность прогноза режима распределительной сети напрямую зависит от точности прогноза ее нагрузки и напряжений.

Авторами проведен обзор ряда публикаций [3-16] о нейронных сетевых моделях, применяемых для краткосрочного прогнозирования электрической нагрузки домовладений и энергосистем, позволивший обосновать выбор моделей нейронных сетей для выполнения прогнозных расчетов режима сети при формировании Навигатором рекомендаций.

ПОСТАНОВКА ЗАДАЧИ

Для проведения конкретных операций с коммутационным оборудованием в отсутствие телеуправления требуются выезды мобильных бригад на объекты сети. Поэтому время, затрачиваемое на переезды и выполнение переключений на объектах района электрической сети, которое варьируется от 15 до 120 и более минут, должно учитываться в рекомендациях диспетчеру, так как за это время нагрузки потребителей и режимы сети могут существенно изменяться. Шаг оперативного планирования в 30 минут выбран в соответствии с регламентами и настройками интервалов интегрирования счетчиков электрической энергии. Поэтому для учёта момента времени выполнения переключений на объектах сети достаточно иметь прогноз режима и топологии сети на 30, 60, 90 и 120 минут вперед от

текущей точки на временной оси. Можно дробить прогнозный горизонт на интервалы в 15 или 10, или 5 минут, но это пока не представляется оправданным.

Предлагается нагрузки прогнозировать на силовых трансформаторах трансформаторных подстанций (ТП) на среднем или низком напряжении. Поясним, почему прогноз нагрузки не целесообразно выполнять на отходящих от ТП линиях 0,4 кВ, которые, как правило, питают группу вводов в конкретные здания, являющиеся потребителями. Эффект осреднения, сглаживания графика нагрузки линии 0,4 кВ слабый, точность прогноза потребления на отходящих линиях 0,4 кВ, даже на современных моделях нейронных сетей, не высока. Эффект начинает проявляться лишь при агрегировании потребления на выводах 0,4 кВ трансформаторов. Кроме того, получить временные ряды потребления для обучения и тестирования моделей прогноза для большинства потребителей 0,4 кВ пока не представляется возможным, за редким исключением. Однако первая очередь цифровой трансформации сетей предусматривает установку приборов учёта на ТП, поэтому в скором времени эта проблема будет решена.

Важный вопрос о моделях и методах прогноза нагрузки и напряжения на центрах питания, напряжений на наблюдаемых шинах распределительной сети остался за рамками статьи. Также опускается рассмотрение несколько важных, но несложных фаз процесса прогноза нагрузки. Например, таких как обработка исходных временных рядов, сегментирование временных рядов нагрузки, которые достаточно хорошо известны.

Задачей данной статьи является определение совокупности моделей прогнозирования нагрузки ТП, которые можно использовать отдельно, в комбинации или в ансамбле моделей, а также определить возможный диапазон ошибки оперативного прогноза этих моделей. Создание ансамблей моделей для прогнозирования нагрузки сети является отдельной большой темой и выходит за рамки статьи.

АНАЛИЗ СОСТОЯНИЯ ВОПРОСА

Потребление на ТП отличается от потребления на центрах питания явно выраженной, индивидуальной формой суточного графика потребления, большим разнообразием типов суточных форм графиков, многочисленными изменениями форм графиков на часовом, су-

точном, недельном, месячном, сезонном и годовом интервалах. Отсутствие большого эффекта осреднения, сглаживания графика потребления ТП связано с существенно меньшим числом конечных потребителей электроэнергии, подключенных к шинам 0,4 кВ ТП, чем потребителей, подключённых к центрам питания. По сравнению с числом потребителей, питаемых фидерами 6-10 кВ центров питания, число потребителей, подключённых к ТП, меньше на порядок и более, а по сравнению с числом потребителей, питаемых подстанциями 35-220 кВ, – меньше на два порядка и более.

Во второй главе книги [3] приведены графики электропотребления при разной степени агрегирования нагрузки на уровне дома, ТП, центра питания. Их анализ показывает, что при повышении степени агрегирования нагрузки графики сглаживаются, при этом агрегированные графики нагрузки могут не соответствовать типу составляющих их графиков нагрузки. Агрегированные графики нагрузки не только более гладкие, но и склонны к более сильной сезонности и погодным зависимостям.

В книге наибольшее внимание уделено работам по исследованию краткосрочного прогноза нагрузки домовладений, зданий, рассматриваемых как отдельных потребителей. Отмечено, что если модели обеспечивают приемлемую точность прогноза потребления отдельных конечных потребителей, то они заведомо обеспечат такую же или более высокую точность прогноза потребления для совокупности таких потребителей – агрегированной нагрузки ТП. Для зданий и домовладений в разных странах мира накоплены многолетние архивы данных о потреблении, источником которых являлись интеллектуальные счетчики электроэнергии.

В ниже представленном обзоре рассмотрены работы, посвященные краткосрочному прогнозу нагрузки зданий, моделям и методам прогнозирования. При анализе публикаций нами выделены наиболее важные оценки и рекомендации авторов в части краткосрочного прогнозирования.

КРАТКОСРОЧНЫЙ ПРОГНОЗ НАГРУЗКИ НА ОСНОВЕ ТРАДИЦИОННЫХ МОДЕЛЕЙ И МЕТОДОВ

В работе [4] рассматриваются традиционные модели и модель SVR (регрессионные опорные вектора), на которых выполняются

прогнозные расчеты больших данных (число потребителей более миллиона). Прогноз нагрузки сети делится на этапы: кластеризация потребителей; анализ факторов, влияющих на нагрузку; формирование дерева решений по выбору кластера для нагрузки; выбор модели SVR для графика нагрузки; выполнение прогноза нагрузки потребителей и всей сети. Описание технологического процесса и общего алгоритма прогноза нагрузки потребителей и всей сети, представленные в [4], являются примером реализации полного процесса краткосрочного прогнозирования режима распределительной сети.

ОБЗОР КРАТКОСРОЧНОГО ПРОГНОЗА НАГРУЗКИ НА ОСНОВЕ СОВРЕМЕННЫХ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ

В обзоре [5] рассматривается прогнозирование электрической нагрузки домовладений и энергосистем на сутки вперед и исследуется применение ряда моделей и архитектур нейронных сетей для прогнозирования. Среди моделей краткосрочного прогноза, работающих на нейронных сетях, выделяются следующие: направленные и рекуррентные нейронные сети; архитектура S2S (последовательность-последовательность или кодирование-декодирование); глубокие сети LSTM (нейронная сеть с долговременной и кратковременной памятью) и CNN (сверточная нейронная сеть). Отмечается, что сети LSTM были адаптированы к краткосрочному прогнозированию нагрузки домовладений и оказались эффективнее традиционных методов анализа временных рядов, градиентных деревьев, SVR, RNN (рекуррентная нейронная сеть). Сети LSTM способны использовать долгосрочные зависимости временных рядов для прогнозирования потребления нагрузки на сутки вперед. Эффективность сетей LSTM связывается с возможностью работать с несколькими переменными. Сеть CNN эффективна для прогнозирования временных рядов нагрузки из-за локальной связности, разделения параметров модели, эквивариантности преобразования. Локальная связность обеспечивается тем, что каждый скрытый нейрон связан с подмножеством входных нейронов, которые находятся близко друг к другу. Сеть CNN устойчива к возможному сдвигу временного ряда на входе. Модели с архитектурой S2S совсем недавно стали использоваться для краткосрочного прогнозирования нагрузки. В одной из работ архитектура S2S на основе

LSTM показала лучшую производительность по сравнению со стандартной моделью LSTM.

КРАТКОСРОЧНЫЙ ПРОГНОЗ НАГРУЗКИ НА ОСНОВЕ МОДЕЛИ LSTM

Анализ состояния вопроса использования модели LSTM для краткосрочного прогнозирования выполнен по работам [6-9].

В работе [6] краткосрочное прогнозирование нагрузки выполняется для отдельных жилых домовладений. Показана разница между электрической нагрузкой дома, обычно она изменчива, и нагрузкой подстанции и энергосистемы, где всегда существуют характерные графики суточного потребления. Образ жизни населения отражается в потреблении энергии в виде повторяющихся характерных графиков, независимо от того, насколько они противоречивы. Поэтому предлагается прогнозирование нагрузки выполнить на основе LSTM, так как эта нейронная сеть запоминает долгосрочные временные зависимости. Современные модели краткосрочного прогноза сравнивались с моделью LSTM на реальном наборе данных. Оказалось, что многие модели, дающие качественный прогноз нагрузки энергосистемы или подстанции, не могут решить задачу прогнозирования нагрузки одного потребителя, а модель LSTM обычно обеспечивает лучшее прогнозирование. Прогнозирование отдельных нагрузок далеко не точное, но в результате агрегирования всех отдельных прогнозов на модели LSTM получается лучший прогноз для уровня агрегации в сравнении с традиционной стратегией прямого прогнозирования агрегированной нагрузки. Несоответствие потребления характерным суточным графикам обычно влияет на предсказуемость нагрузки потребителей, и чем больше это несоответствие, тем больший вклад LSTM может внести в повышение точности прогноза по сравнению, например, с простой нейронной сетью с обратным распространением.

В работе [7] отмечается, что прогнозирование нагрузки для одного домовладения затруднено из-за изменчивости графика временного ряда нагрузки. Модель LSTM лучше работает за счет установления значимых временных взаимосвязей между нагрузками на интервалах времени. Когда доступны составляющие внутримодульной нагрузки, то при использовании LSTM точность прогнозирования агрегированной нагрузки дома повышается.

В работе [8] описывается оптимизированная одномерная модель LSTM, применённая для краткосрочного и среднесрочного прогнозирования нагрузки метрополитена Парижа (Франция). Модель на основе LSTM оказалась точнее других семи моделей машинного обучения. Включение переменных, наиболее влияющих на прогноз, во входные данные модели способствует повышению точности прогноза.

В статье [9] авторы использовали LSTM для прогноза агрегированного электропотребления на данных, полученных за 13 месяцев. Точность прогноза модели LSTM сравнивалась с точностью прогноза следующих моделей: ARMA (статистическая модель прогноза с автоматической регрессией, со скользящим средним), SARIMA (статистическая модель прогноза с автоматической регрессией, с интегрированием, со скользящим средним, с учетом сезонности), ARMAX (статистическая модель прогноза с автоматической регрессией, с интегрированием, со скользящим средним, с учетом внешних переменных). Показано, что модель LSTM быстрее обрабатывает временные ряды данных, а точность прогноза модели LSTM может быть повышена при увеличении количества переменных. При наличии достаточно длинного временного ряда, LSTM может “узнать” все сезоны и тренды. LSTM превосходит традиционные модели в части анализа временных рядов и точности прогноза нагрузки. LSTM демонстрирует устойчивость к повышению неопределенности характера нагрузки с увеличением горизонта прогноза нагрузки.

КРАТКОСРОЧНЫЙ ПРОГНОЗ НАГРУЗКИ НА ОСНОВЕ МОДЕЛИ CNN

Для краткосрочного прогноза нагрузки в работе [10] предложена нейронная сеть на основе свертки под названием Deep Energy. Модель прогноза представлена двумя частями – моделью обучения или извлечения зависимостей нагрузки из временных рядов и собственно моделью прогноза. Извлечение зависимостей выполняется тремя слоями свертки и тремя пулами. Слои свертки одномерные. Размеры ядер в слоях свертки равны 9, 5, 5 соответственно, а глубина преобразования свойств равна 16, 32, 64. Метод всех трех пулов – максимальный, размер – 2. Прогноз выполняется слоем выравнивания и выход-

ным слоем. Для прогнозирования в качестве исходных данных использовались временные ряды потребителей из штата Техас (США), собранные за 3 месяца. После подбора параметров модели автор провел эксперименты по обучению модели на недельном интервале и по прогнозированию на трое суток вперед, после чего сравнил эффективность использования сети Deep Energy с эффективностью нескольких других моделей: модели на основе SVR, модели случайных деревьев, модели решений на основе деревьев, LSTM. Оказалось, что модель Deep Energy показывает более точный прогноз, однако на коротких временных рядах модель CNN превосходит другие модели.

В работе американских прогнозистов [11] исследуется эффективность модели CNN при прогнозировании нагрузки индивидуального домовладения. В модели используются два слоя свертки, за каждым из которых располагается слой нелинейного преобразования и пул. В отличие от работы [10], авторы к полностью связанному слою, идущему за последним пулом, проводят объединение важных данных, влияющих на точность прогноза: часа суток; месяца в году; дня недели; дня месяца; флага выходных. Модель настраивается изменением фильтров, размера ядра, фильтрами пулов, числом и размерами слоев свертки. Результаты, полученные на модели CNN для конкретного временного ряда, сравнивались с результатами, полученными на следующих моделях: LSTM в архитектуре S2S; FCRBM (факторная, условно ограниченная машина Больцмана); ANN (искусственная нейронная сеть) и SVR. Экспериментальные результаты показали, что модель CNN превзошла SVR, сопоставима с ANN и DNN (глубокая нейронная сеть). Результаты прогнозирования CNN не сильно зависят от архитектуры модели, однако в качестве входных данных в алгоритмы обучения важно добавить сведения о погоде.

КРАТКОСРОЧНЫЙ ПРОГНОЗ НАГРУЗКИ НА ОСНОВЕ КОМБИНИРОВАННЫХ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ

В статье [12] предлагается комбинированная нейронная сеть LSTM и CNN, состоящая из трех частей: параллельных LSTM и CNN; модуля объединения и полностью связанного слоя. Предложенная модель позволяет анализировать временные ряды нагрузки в реаль-

ном времени. Входными данными для модели являются временные ряды нагрузки за последние несколько часов, а выходными – прогноз нагрузки. Для сравнения эффективности моделей выполнено прогнозирование нагрузки с использованием нескольких моделей, включая модели CNN и LSTM. Модель CNN собрана из трех одномерных слоев свертки с функцией активации RELU. Скрытые нейроны вывода LSTM такие же, как и в CNN. Выходы двух модулей объединяются в слое слияния, после чего в полностью связанном слое делается окончательный прогноз. В качестве исходных данных для прогнозирования использовались агрегированные почасовые данные нагрузок потребителей севера Италии за три года. Модель LSTM запоминает долгосрочные зависимости, поэтому гибридная модель эффективно использует преимущества каждого своего компонента и интегрирует скрытые свойства CNN и LSTM для достижения более высокой точности и стабильности прогноза. Производительность гибридной модели намного выше, чем у дерева решений и случайных деревьев. Прогноз, выполняемый с использованием гибридной модели CNN и LSTM точнее, чем у Deep Energy [10], а у модели CNN точнее, чем у модели LSTM. Предлагаемая гибридная модель CNN и LSTM, обеспечивает лучший и более стабильный результат по сравнению с другими моделями.

В работе [13] также рассматривается комбинированная нейронная сеть, основанная на последовательном соединении CNN и LSTM, а не параллельном, как в [12]. Такая гибридная модель работает так: CNN извлекает важную информацию из входных данных и реорганизует одномерные входные данные в многомерные наборы с использованием свертки. Далее эти наборы вводятся в блоки LSTM для прогнозирования. Использование гибридной модели проверялось на пяти реальных наборах данных по энергопотреблению домовладений в Лондоне. Показано, что гибридная модель CNN-LSTM эффективнее ARIMA, SVR и LSTM.

В статье [14] предложена гибридная модель CNN-RNN для краткосрочного прогнозирования нагрузки. CNN извлекает взаимосвязи из временных рядов нагрузки, рекуррентные компоненты моделируют неявную динамику, полносвязные слои преобразуют свойства. Сеть FNN (нейронная сеть прямого распространения) используется для моделирования внешних переменных, таких как, температура

окружающей среды, праздничные дни, час дня, день недели. Одновременно FNN используется для проецирования внешних переменных в векторные представления. Для прогнозирования нагрузки все “изученные” свойства объединяются через полносвязные слои. Оценка работы модели проводилась на 3-х летнем наборе данных почасовой городской нагрузки на севере Китая. Результаты расчетов продемонстрировали приемлемую точность прогноза такой гибридной модели. Использование нескольких параллельных компонентов CNN с различным размером фильтра отличается от укладки слоев каскадом и позволяет CNN обучаться более широкому спектру свойств входного временного ряда нагрузки.

В статье [15] авторы предложили последовательный гибридный CNN-LSTM с несколькими скрытыми слоями для прогнозирования энергопотребления жилого дома. CNN извлекает взаимосвязь между несколькими переменными, влияющими на потребление, а LSTM – информацию о нерегулярных тенденциях компонентов временных рядов. С выхода LSTM данные передаются на полностью связанный слой. Гибридная модель выдает более точный прогноз по сравнению с традиционными моделями. CNN среди нескольких переменных выделяет важные характеристики, влияющие на прогноз потребления, устраняет шум. Авторы меняли разрешение данных по времени и получили подтверждение того, что CNN уменьшает спектр данных. Слой CNN может принимать различные переменные, такие как напряжение, ток, мощность ЭП, которые влияют на потребление электрической энергии. Такие характеристики как дата, время, поведение жителей и занятость домовладения, также могут быть использованы как метаинформация на уровне CNN. Отмечено, что гибридный CNN-LSTM работает эффективнее линейной регрессии, регрессии случайных деревьев, регрессии дерева решений и многослойного перцептрона, LSTM, GRU (нейронная сеть с управляемыми рекуррентными нейронами), Bi-LSTM (двухнаправленная LSTM).

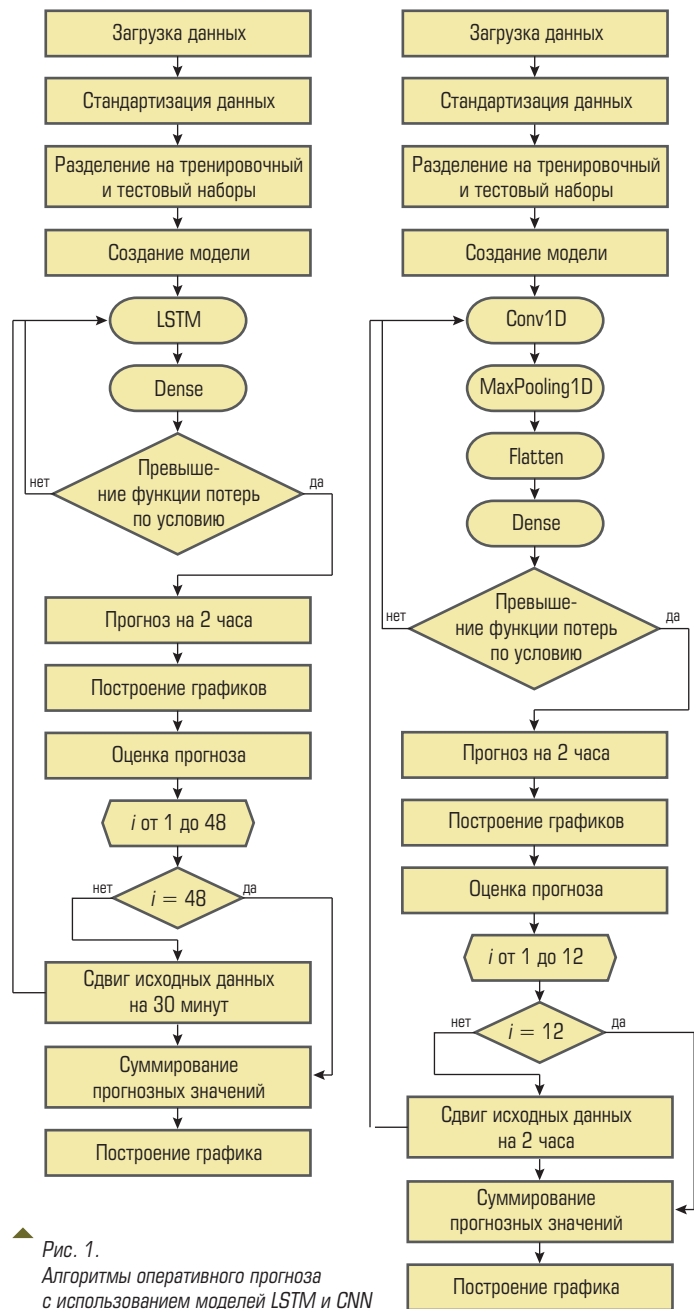
Из обзора современных моделей краткосрочного прогноза нагрузки домовладений, энергосистем, следует, что наиболее перспективными моделями для оперативного прогноза нагрузки ТП на данный момент являются модели CNN и LSTM, архитектуры S2S, а также их комбинирование, использование в ансамблях.

**АРХИВ ПОТРЕБЛЕНИЯ
ТРАНСФОРМАТОРОВ**

Из открытых данных о потреблении электроэнергии различными зданиями, домо-владениями, квартирами, более всего подошел “португальский” набор данных, включающий архивы потребления электроэнергии 370-ти зданий [16]. Данные представлены 15-ти минутными замерами нагрузок в кВт, выполненными с 2011 г. по 2014 г., и представленными в формате CSV. Также для этого промежутка времени представлены данные о погоде. Графики потребления зданий были подобраны таким образом, чтобы составленные суммированием почасовых нагрузок зданий графики трансформаторов были явно сегментированы. Графики образовали два выраженных сегмента – жилой (квартиры, отдельные жилые дома) и нежилой (офисы, магазины и т.п.). Из двух характерных типов графиков – с двумя пиками (жилой сегмент) и одним плато (нежилой сегмент) в основном работали с графиком жилого сегмента. Прогнозы нагрузки нежилого сегмента получаются слишком точные, поэтому дальше их не рассматривали. Пиковая составная нагрузка трансформатора составила около 2 МВт. Для проведения расчетов данные потребления были преобразованы из 15-минутки в 30-минутки.

**ОПЕРАТИВНЫЙ ПРОГНОЗ
НАГРУЗКИ ТРАНСФОРМАТОРА
НА МОДЕЛИ LSTM И CNN**

При разработке моделей оперативного прогнозирования на основе глубоких нейронных сетей использовались рекомендации авторов рассмотренных выше публикаций по архитектуре моделей, настройке методов сходимости, параметрам моделей. Разработанная модель на основе LSTM настраивалась путем изменения числа слоев, изменения числа нейронов в каждом слое, изменения числа эпох при обучении, изменения оптимизационных методов и т.д. Предусмотрено включение в модель дополнительных переменных по результатам анализа значений коэффициентов корреляции Пирсона, и опытным путем, исключением по одной переменной из обучения и прогноза. Влияние на потребление в порядке убывания оказывают следующие переменные: час в сутках; сезон; день недели; внешняя температура. Технология настройки разработанной модели на основе CNN ана-



▲ Рис. 1. Алгоритмы оперативного прогноза с использованием моделей LSTM и CNN

логична настройке LSTM. Для CNN самыми важными параметрами для настройки являются величина ядра и размер фильтра. Алгоритмы оперативного прогноза потребления на модели LSTM и CNN представлены на рис. 1. Алгоритмы включают загрузку данных – чтение данных из архива; стандартизацию данных – выявление выбросов и нулевых значений; замену их интерполяцией; масштабирование – приведение к шкале от 0 до 1. Тренировочный и тестовый наборы – это 80% и 20% архива. Создание модели – это инициализация модели с параметрами, которые

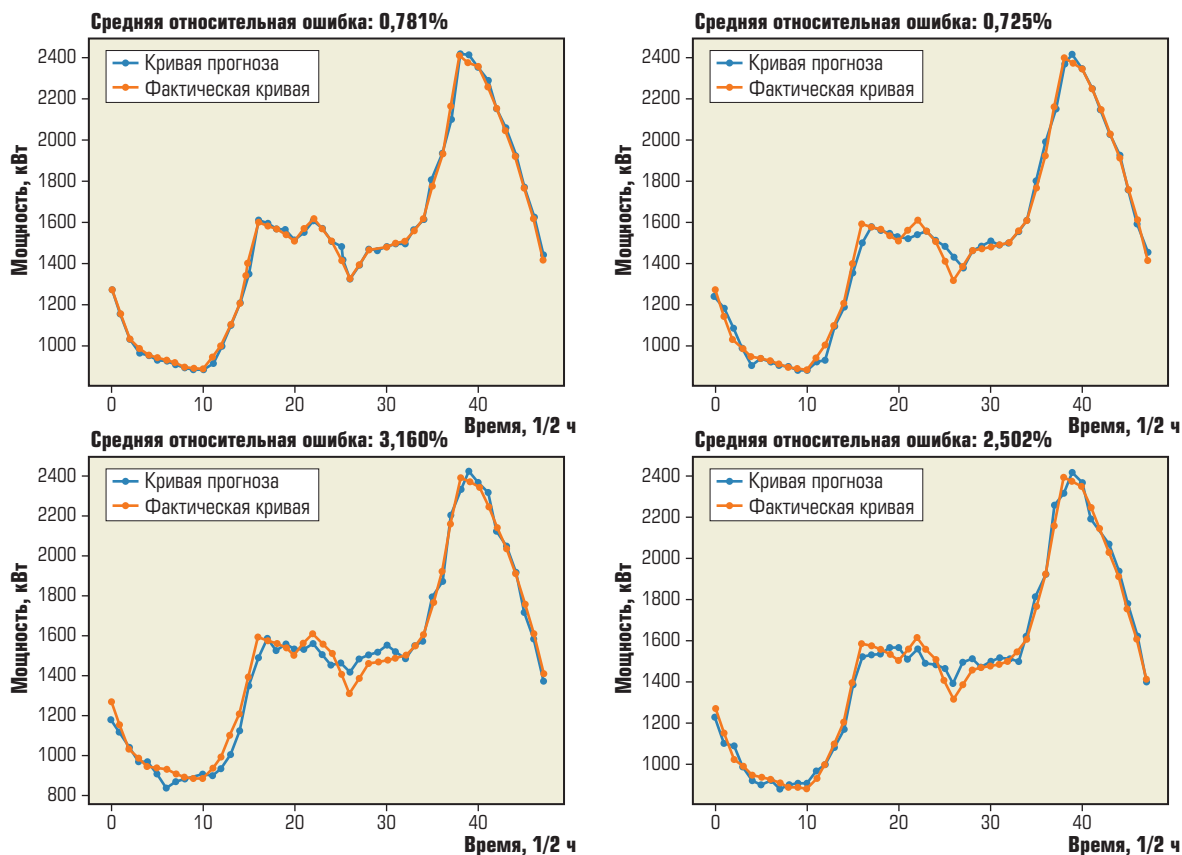


Рис. 2. Графики оперативного прогноза нагрузки трансформатора для “хороших” суток на модели LSTM на 30, 60, 90 и 120 минут вперед (слева сверху по часовой стрелке)

Таблица 1. Статистика ошибки оперативного прогноза нагрузки трансформатора для “хороших” суток на модели LSTM

Горизонт прогноза, мин		30	60	90	120
Ошибка прогноза	Математическое ожидание, %	0,78	1,33	1,83	2,35
	Среднеквадратическое отклонение, %	0,99	1,41	1,21	1,60

указаны в коде программы или считываются из конфигурационного файла (базы данных). Полносвязный слой может быть одинарным или двойным. Потери в условии по превышению определяются по среднеквадратической ошибке. Прогноз на 2 часа предусматривает расчет потребления в 4-х точках на оси времени – на 30, 60, 90, 120 минут вперед. Такой прогноз в цикле выполняется 48 раз. При этом, после окончания каждого цикла, следующая начальная точка прогноза смещается на 30 минут вперед – на одну точку вперед по временной оси. В реальном времени это позволяет всегда иметь оперативный прогноз на 2 часа вперед и корректировать предыдущий прогноз на каждые полчаса, т.е. для 3-х точек из предыдущего прогноза на 30, 60 и 90 минут вперед. Величина коррекции предыдущего прогноза может проверяться абсолютной и интегральной апертурой на предмет необхо-

димости пересчета предыдущего спрогнозированного установившегося режима, других сложных функций, использующих расчетные параметры режима трансформатора и всего фидера, питающего ТП.

Для иллюстрации работы модели LSTM были выбраны “хорошие” (30.01.2014) и “плохие” (01.01.2014) сутки по критерию соответствия графика прогноза типовому. На рис. 2 приведен пример графика, а в таблице 1 – статистика ошибок для “хорошего” оперативного прогноза нагрузки трансформатора на модели LSTM на 30, 60, 90 и 120 минут вперед.

“Плохой” для прогноза день случился 01.01.2014, когда произошел провал нагрузки в середине дня. Мы специально не стали вводить в модели категорию “праздничные дни”, чтобы получить максимальный эффект “плохих” суток. На рис. 3 приведен пример графика, а в таблице 2 статистика ошибки

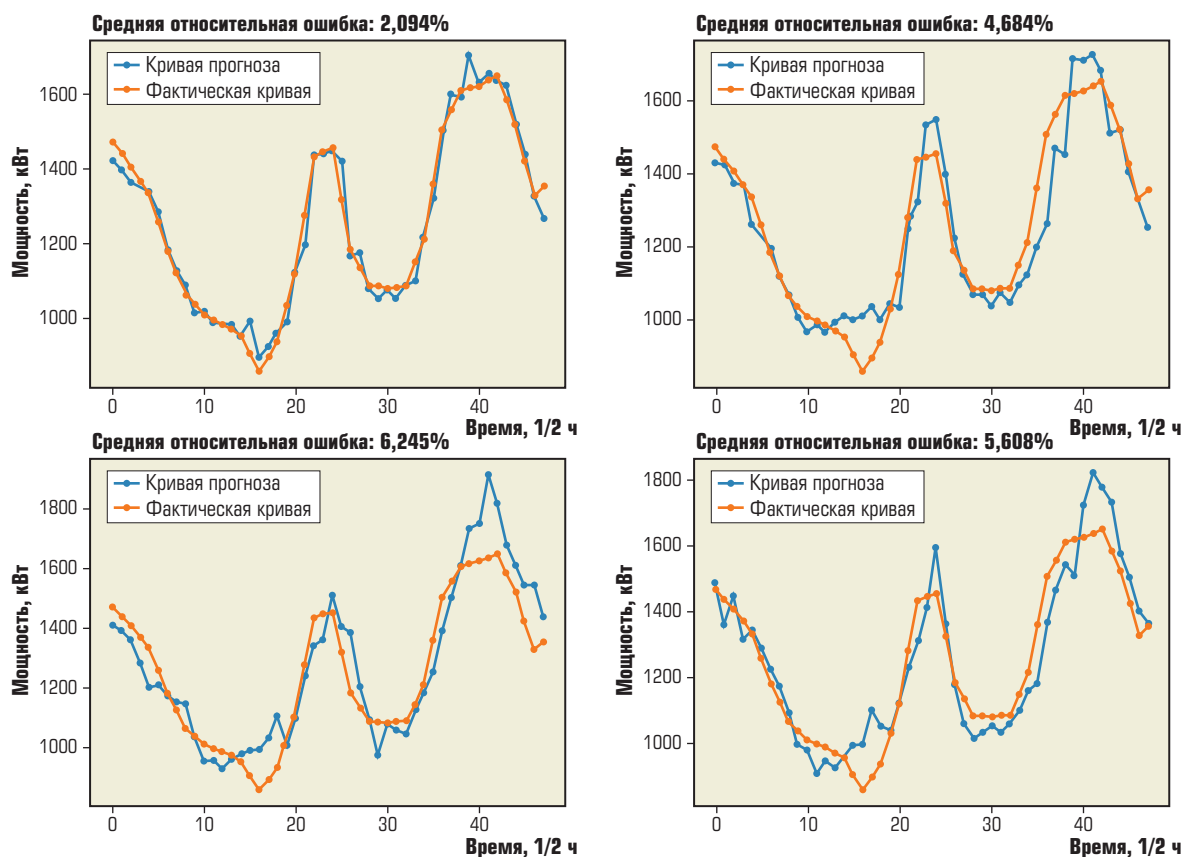


Рис. 3. График оперативного прогноза нагрузки трансформатора модели LSTM для “плохих” суток на 30, 60, 90 и 120 минут вперед (слева сверху по часовой стрелке)

Таблица 2. Статистика ошибки оперативного прогноза нагрузки трансформатора для “плохих” суток на модели LSTM

Горизонт прогноза, мин		30	60	90	120
Ошибка прогноза	Математическое ожидание, %	1,77	3,47	3,92	4,53
	Среднеквадратическое отклонение, %	2,14	2,89	2,89	2,67

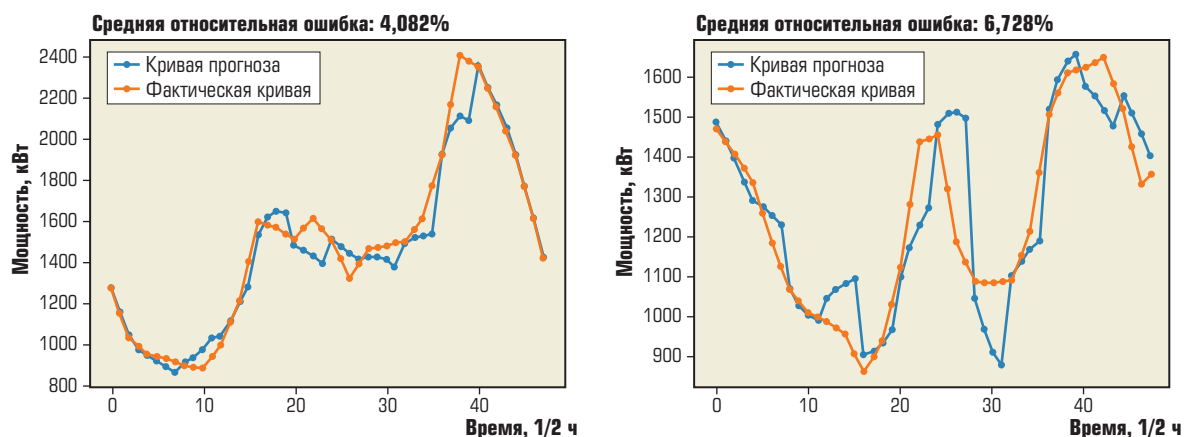


Рис. 4. Графики оперативного прогноза нагрузки трансформатора модели CNN для “хороших” (слева) и “плохих” (справа) суток на 2 часа вперед

оперативного прогноза нагрузки трансформатора на модели LSTM для “плохих” суток на 30, 60, 90 и 120 минут вперед (слева сверху по часовой стрелке).

Примеры графиков оперативного прогноза нагрузки трансформатора на модели CNN на 2 часа вперед для “хороших” и “плохих” суток представлены на рис. 4.

ЗАКЛЮЧЕНИЕ

Практика использования моделей глубоких нейронных сетей, апробированных на множестве архивов нагрузок потребителей и трансформаторов, подтверждает принципиальную возможность выполнения оперативного прогноза нагрузки ТП с требуемой точностью. Прогноз режима сети выполняется для каждого момента времени исполнения рекомендации Навигатора по изменению топологии или положения регуляторов оборудования сети на основе прогноза нагрузки ТП. Это позволяет использовать Навигатор для оперативного управления режимом и топологией для наблюдаемой части распределительной сети в автоматическом режиме.

Список литературы

1. Рыкованов С.Н., Хозяинов М.А. “Концепция навигатора диспетчера для адаптивного оптимального управления режимами распределительной электрической сети” // Автоматизация & ИТ в энергетике. 2018, № 12(113), с. 30-34.
2. Потапенко С.П., Рыкованов С.Н., Хозяинов М.А. Навигатор диспетчера. Адаптивная динамическая оптимизация потерь электроэнергии в разомкнутой распределительной электрической сети // “Электроэнергия. Передача и распределение”. 2019, № 5(56), с. 53-59.
3. Jacob M. et al., Forecasting and Assessing Risk of Individual Electricity Peaks. Chapter 2 Short Term Load Forecasting, Mathematics of Planet Earth. 2020, https://doi.org/10.1007/978-3-030-28669-9_2
4. Zhang P., Wu X., Wang X., Bi S. Short-Term Load Forecasting Based on Big Data Technologies. CSEE JOURNAL OF POWER AND ENERGY SYSTEMS, VOL. 1, NO. 3, SEPTEMBER 2015.
5. Gasparin A., Lukovic S., Alippi C. Deep Learning for Time Series Forecasting: The Electric Load Case. Project: Swiss Competence Center for Energy Research on the Electrical Infrastructure (SCCER-FURIES), 2019.
6. Kong, W., Dong, Z.Y., Jia, Y., Hill, D.J., Xu, Y., Zhang, Y. Short-term residential load forecasting based on LSTM recurrent neural network. IEEE Transctions. Smart Grid (2017).
7. Kong, W., Dong, Z., Hill, D., Luo, F., Xu, Y. Short-term residential load forecasting based on resident behaviour learning. IEEE Trans. Power Syst. 2018, 33, 10871088.
8. Bouktif S., Fiaz A., Ouni A., Adel Serhani M. Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches. Energies 2018, 10, 1168.
9. Muzaffar S., Afshari A. Short-Term Load Forecasting using LSTM Networks. Energy Procedia 158 (2017).
10. Cuo P., Huang C. A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting. Energies. 2018.
11. Amarasinghe K., Marino D., Manic M. Deep Neural Networks for Energy Load Forecasting. IEEE 26th International Symposium on Industrial Electronics (ISIE) 2017.
12. Tian C., Ma J., Zhang C., and Zhan P. “A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network,” Energies, vol. 11, p. 3493, 12 2018.
13. Yan K., Wang X., Du Y., Jin Ning., Huang H., Zhou H. Multi-Step Short-Term Power Consumption Forecasting with a Hybrid Deep Learning Strategy. Energies. 2018.
14. He W. “Load forecasting via deep neural networks,” Procedia Computer Science, vol. 122, pp. 308-314, 2017, 5th International Conference on Information Technology and Quantitative Management, ITQM 2017.
15. Kim T., Cho S. Predicting residential energy consumption using CNN-LSTM neural Networks. Energy 182, 2019.
16. <https://archive.ics.uci.edu/ml/machine-learning-databases/00321/>

*Арапов Николай Дмитриевич – инженер ООО “Прикладные программы”,
 Беляков Дмитрий Андреевич – инженер ООО “Прикладные программы”,
 Московой Иван Валерьевич – инженер ООО “Прикладные программы”,
 Рыкованов Сергей Николаевич – канд. техн. наук, генеральный директор ООО “Систел”,
 Хозяинов Михаил Александрович – заместитель генерального директора по развитию ООО “Систел”.*