

## **ПРОГНОЗИРОВАНИЕ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ**

**С.С. НИКОЛАЕВ, Ю.А. ТИМОШЕНКО**

Кратко рассмотрено состояние энергосетей в Украине и за рубежом. Показана актуальность создания сетей нового поколения, а также приведена постановка задачи управления смарт гридом и подзадач, которые при этом возникают. Предложено решение задачи прогнозирования электроэнергии с помощью нейронных сетей. Рассмотрена структура и описан выбор параметров нейронной сети для составления суточных прогнозов потребления электричества. Описан алгоритм обучения сети, входные и выходящие данные. Описана процедура отбора входных признаков. Проведён анализ зависимости точности прогноза от выбора входных признаков. Выявлено, что при подаче на вход сети в качестве отдельных признаков индикаторов праздничных дней, можно улучшить качество прогнозируемого результата. Также показано влияние погодных факторов на точность получаемых прогнозов.

### **ВВЕДЕНИЕ**

Традиционно задача прогноза всегда была важна в связи с необходимостью планирования выработки электроэнергии.

Раньше энергосети состояли в основном из нескольких типов электростанций (ТЭС, ГЭС, АЭС), небольшое количество которых, производило практически всю энергию. При этом, для управления и стабилизации всей энергосети как целостного объекта, было достаточно простых систем управления отдельными станциями.

Современные энергетические системы начинают включать кардинально разнородные по своим свойствам и мощностям виды генерирующих электростанций и потребителей. Всё больше стран начинают массовое внедрение возобновляемых источников энергии в нашу жизнь, таких, как солнечные панели на крышах домов и ветряные электростанции. Появляются новые типы потребителей электричества, например: электроавтомобили, которые могут, как заряжаться от сети, так и отдавать энергию из аккумуляторов обратно в сеть; бытовые приборы со встроенными умными контроллерами в качестве концепции Internet Of Things, которые позволяют в реальном времени через интернет влиять на работу миллионов устройств.

Теперь в одной сети могут одновременно работать как газовые турбины, так и солнечные электростанции с хранилищами литий-ионных аккумуляторов на пару десятков мегаватт. Но вот если газовой турбине для разгона

необходимо около четырёх часов и она в принципе из-за высокой инерции не в состоянии быстро менять ни фазу ни частоту генерируемой электроэнергии, то солнечные электростанции запросто способны нивелировать эффект проходящих над ними туч, подключая резервы хранилищ. Это ведёт к рассредоточению сети, в которой теперь присутствует множество разнородных элементов. Такая комбинация разнородных источников энергии в одной системе, с одной стороны даёт возможность мгновенно реагировать на изменение потребления в отдельных её участках, с другой — усложняет её управление.

Также, учитывая рост нагрузки на энергетические системы и изношенность инфраструктуры самих сетей, перед современными исследователями встала задача заново научиться управлять [1] и распределять [2] нагрузку между потребителями в пространственном и временном контексте в новом энергетическом пространстве. Особенно остро в мире стал вопрос стабильности всей энергосистемы после нескольких крупных аварий, например, такой, которая произошла с американским гридом. Он оказался плохо устойчивым к отказам узлов системы, вследствие чего при аварии на одном узле, наблюдались колебания частоты и перекося фаз, которые привели к цепному отказу десятков других станций. При этом было обесточено значительное количество населённых пунктов. Для решения данной проблемы, необходимо более фундаментальное управление, основанное на прогнозировании нагрузки в разных частях и в разное время функционирования системы, а также гибкое перераспределение ресурсов системы.

Для новой энергосети нужно создать новые системы управления, которые в реальном времени по сети интернет будут не только перенастраивать параметры отдельных узлов энергосети, но и переконфигурировать её структуру на всех уровнях вплоть до изменения потребления энергии самими потребителями.

Насколько известно, в Украине данная постановка задачи не решалась.

В частности, для работы таких систем управления необходим точный прогноз потребления энергии, чтобы заранее создать план перераспределения нагрузки.

Учитывая несоответствие стандартов и инфраструктурных решений украинских энергосистем с европейскими, при их интеграции в ближайшем будущем данная задача станет актуальной и в Украине.

На данный момент оптовый рынок электрической энергии (ОРЭ) Украины состоит из 5 энергогенерирующих компаний: тепловых электростанций, атомных электростанций и гидроэлектростанций. Каждая из компаний должна предоставлять услуги по регулированию нагрузки (маневровые мощности) в Объединенной энергосистеме Украины (ОЭС).

В связи с предстоящей интеграцией ОЭС Украины в UCTE (Union for the Coordination of Transmission of Electricity — союз по координации передачи электроэнергии) необходимо привести допустимый уровень отклонений частоты генерации тока, который по украинским стандартам составляет  $\pm 0,2$  Гц, к стандартам UCTE, а именно к  $\pm 0,02$  Гц [3].

За поддержку системы обеспечения функционирования ОРЭ отвечает государственное предприятие «Энергорынок», которое выполняет ежедневное почасовое планирование режима работы объединенной системы с актив-

ной энергией и мощностью на основе оптимизации режимов работы электростанций, внешних перетоков электроэнергии, и представленного генерирующими компаниями прогнозного объема потребления электроэнергии на следующие сутки. Чтобы избежать пиковых нагрузок, которые оказывают значительное влияние на частоту в сети, производится планирование ежесуточной почасовой выработки электроэнергии энергосистемой для оптимальной работы производителей энергии. Следовательно, чем точнее будет прогноз, тем меньше вероятность возникновения перегрузок и внештатных ситуаций, что делает задачу повышения качества прогнозирующих моделей актуальной.

На западе всё больше исследований проводится по созданию интеллектуальной энергосети или Smart Grid, которая должна планировать распределение нагрузки в масштабах целых стран. Концепция Smart Grid позволяет по-новому подходить к построению электрических сетей, переходя от жесткой структуры «генерация – передача по сети – потребитель» к более гибкой, в которой каждый узел сети может являться элементом как производящим, так и потребляющим энергию.

При этом на системы управления и контроля накладывается следующее множество ограничений и критериев:

- минимизация затрат на генерацию энергии;
- минимизация потерь энергии при её передаче потребителям;
- минимизация количества и продолжительности пиковых нагрузок;
- рациональное использование энергии самими потребителями;
- ограничения устойчивости:

– частота и напряжение в сети по всему гриду должна находиться в пределах жёстко заданного коридора значений, даже в случае сбоя на отдельных узлах-электростанциях;

– должен полностью удовлетворяться спрос в любой период и в любой точке сети с учетом вероятности возникновения пиков потребления и перегрузок.

В качестве управляемых структур присутствуют:

- Рынок электричества — грид диктует ценовую политику таким образом, чтобы сделать нагрузку на сеть более равномерной на протяжении дня, при этом пользователи подстраивают потребление для минимизации стоимости используемого ими электричества.

- Множество аккумулирующих станций (литий ионных, гидроаккумулирующих станций, электрокаров и др.).

- Множество хозяйственных управляемых объектов (цеха, склады, всевозможные стиральные машины с контроллерами, управляемыми по сети командами от грида, и вообще любые структуры, где можно перераспределять интенсивность потребления энергии во времени таким образом, чтобы не нарушить технологический процесс).

- Управление непосредственно самими производственными мощностями электростанций.

При этом интеллектуальная энергосеть в автоматическом режиме производит изменение конфигурации в изменяющихся условиях, планирует распределение нагрузки, и прогнозирует количество потребляемой энергии [4].

Сформулируем математическую модель управления гридом и системы прогнозирования потребления энергии.

## ПОСТАНОВКА ЗАДАЧИ

Современная постановка задачи управления гридом могла бы звучать следующим образом: найти управление производством энергии разнотипными электростанциями и потреблением электроэнергии разными категориями пользователей, подключённым к единой сети, на заданный период  $T$  (например, 24 часа с почасовой дискретизацией), при котором выполняются ограничения и достигаются критерии перечисленные выше. В математической формулировке они выглядят таким образом:

$$\min \sum_i \sum_t q_i(t), \quad \min \sum_j \sum_t I(c_j(t) > \phi_{c_j(t)}),$$

$$\min \sum_j \sum_i \sum_t C(c_j(t), q_i(t)),$$

$$\sum_i q_i(t) = \sum_j c_j(t), \forall t \in [0..T],$$

$$L(c_j(t), q_i(t)) < l_{ij}, \quad q_i(t) < Q_i - v_{q_i(t)},$$

где

$q_i(t)$  — количество энергии вырабатываемое  $i$ -й станцией в промежутке времени  $[t, t+1)$ ;

$c_j(t)$  — количество энергии, потребляемое  $j$ -м потребителем в промежутке времени  $[t, t+1)$ ;

$C(c_j(t), q_i(t))$  — затраты на передачу энергии от  $i$ -й станции до  $j$ -го потребителя;

$L(c_j(t), q_i(t))$  — прямая пропускная способность линий передачи от  $i$ -й станции до  $j$ -го потребителя;

$l_{ij}$  — максимальная прямая пропускная способность линий передачи от  $i$ -й станции до  $j$ -го потребителя;

$\phi_{c_j(t)}$  — объем энергии, потребление свыше которого считается пиковым (в общем случае зависит от динамики потребления в определённом сегменте сети);

$I(c_j(t) > \phi_{c_j(t)})$  — индикаторная функция, которая равна 1, если условие выполняется и 0 в противном случае;

$Q_i$  — максимально возможный производимый объем энергии  $i$ -й станцией;

$v_{q_i(t)}$  — резерв ресурсов  $i$ -й станции, который не может быть задействован на данном промежутке  $[t, t+1)$ . Например, газовая турбина не может разогнаться с нуля до максимума за один промежуток времени, потому в начале разгона  $v_{q_i(t)}$  будет принимать значения близкие к  $Q_i$ , постепенно падая со временем. Также, данный резерв может задавать границу, за которую не желательно выходить по технологическим причинам.

При выполнении условий выше, считается, что сеть работает в штатном режиме и, соответственно, частота и напряжение в сети по всему гриду будут находиться в допустимых пределах.

Учитывая обозначения, необходимо найти такие значения  $q_i(t)$ , которые удовлетворяют ограничениям выше, при заданных пропускных способностях. При этом в общем случае значения  $c_j(t)$  на решаемый период неизвестны, а известна история потребления за предыдущие периоды, на основании которых нужно строить прогноз.

Традиционно задача прогноза количества потребляемой энергии решалась с помощью регрессионных моделей, но так как данные ряды потребления энергии не являются стационарными, то регрессионные модели дают большие ошибки.

Мы хотим создать инструментарий для решения задачи прогнозирования количества потребляемой энергии. Данная задача решалась разными методами. Мы выбрали в качестве метода для прогнозирования искусственные нейронные сети.

Для решения задачи с использованием нейронных сетей необходимо:

- Отобрать информативные входящие признаки.
- Выбрать оптимальную структуру сети, а именно количество скрытых слоёв и нейронов.
- Обучить сеть до оптимального по заданному критерию уровня.

**Цель работы** — построить нейронную сеть, которая будет выдавать прогноз с минимальным отклонением от действительных значений потребления энергии.

В математической формулировке критерий может быть представлен в виде:

$$\min_W \sum_i (y(W, x_i) - w(i))^2,$$

где  $W$  — обучаемые параметры сети;  $y(w, x_i)$  — спрогнозированное значение нагрузки на момент  $i$  при заданном векторе входных факторов  $x_i$ ;  $w(i)$  — действительные значения нагрузки в момент  $i$ .

Критерий рассчитывается по той части выборки, которая не участвовала в обучении сети. Соответственно выбирается множество индексов  $\{i\}$ .

Далее будет описана методика построения прогноза при помощи искусственных нейронных сетей.

## ВХОДНЫЕ ДАННЫЕ

Набор исходных данных получен из источника [5] и состоит из замеров потребления энергии по двадцати штатам США и температур воздуха с одиннадцати метеостанций. Взаимное расположение метео- и электростанций в выборке не известно.

Данные хранятся в виде набора из двадцати таблиц, каждая с которых представляет собой: номер записи, год, месяц, день, и нагрузку за каждый из двадцати четырёх часов. В каждой таблице приведено по 1650 записей (строк), что соответствует 39600 значениям нагрузки сети.

Минимальное и максимальное значения нагрузки по всей выборке, составляет соответственно: 7319 и 45547 мегаватт.

Сбор и включение в модель погодных данных необходим потому, что субъективное ощущение холода людьми сильно влияет на их решение

о включении обогревательных приборов. Соответственно можно наблюдать всплески потребления энергии в дни, когда температура резко падает. Также заметно влияет влажность и сила ветра.

Приведём вид части данных потребления и температур из выборки:

На рис. 1 показан график исходных данных потребления электроэнергии одним штатом в течении года. По оси абсцисс отложено время суток (в часах от 0 до 24), по оси ординат — дни (от 0 до 365). По оси аппликат отложена нагрузка в мегаваттах.

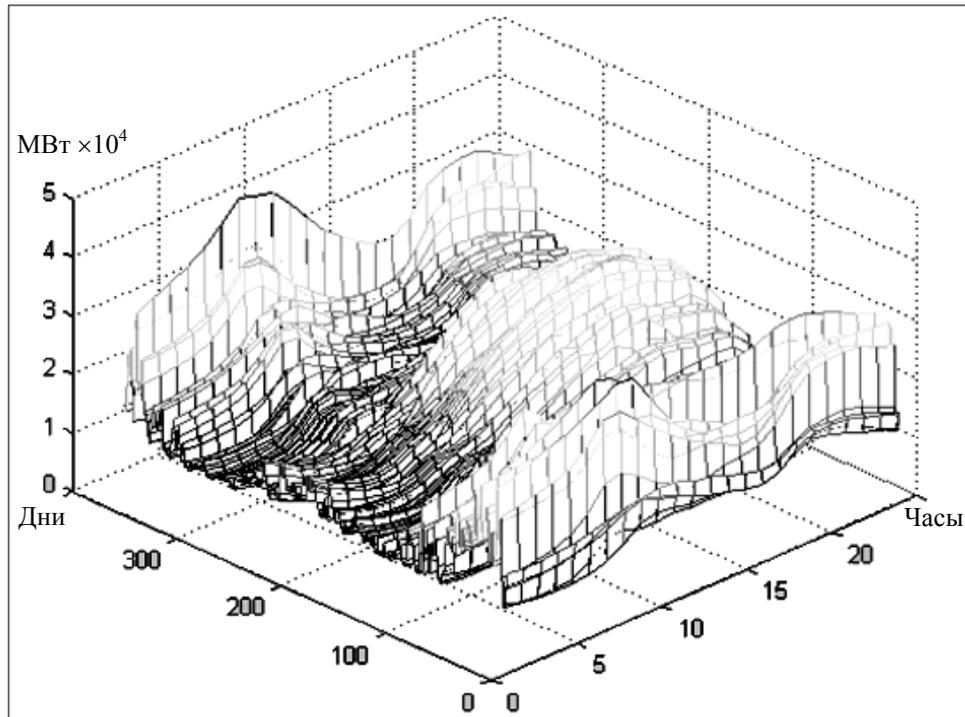


Рис. 1. Пример данных потребления энергии одним регионом

В данных хорошо проглядывается смена сезонов. Так в средней части графика (если смотреть по дням — в промежутке с 130-го по 250-й день), хорошо виден тёплый период года, когда ночью и утром наблюдается минимум потребления энергии, а вечером — её максимум, что можно объяснить включениями кондиционеров после обеда. Также хорошо виден зимний период — в начале и в конце графика (по дням). Тут потребление энергии совершенно другого характера: ночью и утром — максимум, а в обед минимум, что можно объяснить массовым включением обогревательных приборов на ночное время, и выключением их в рабочее время. Утренний пик можно объяснить включением обогревательных приборов на рабочих местах и массовым приготовлением кофе, завтраков на электроплитах и другими факторами.

На рис. 2 показан график исходных значений температур снятых с одной станции за год. По оси абсцисс отложено время суток (в часах 0–24), по оси ординат — дни (0 – 365). По оси аппликат отложена температура воздуха (в градусах Фаренгейта).

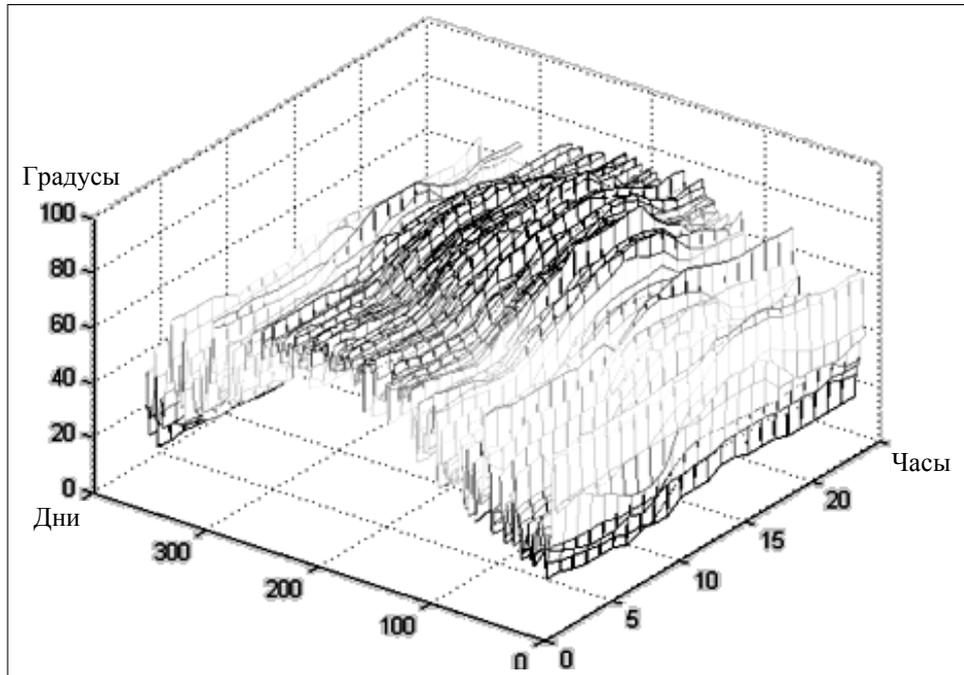


Рис. 2. Пример данных температур воздуха за год

В центральной части видны высокие летние температуры, которые достигают пика в обеденное время и спадают к вечеру. По концам графика (по оси — дней) — видны низкие зимние температуры, которые не сильно изменяются на протяжении суток.

Если рассматривать график последовательно по дням (один день — двадцать четыре часовых отсчёта по оси абсцисс), то иногда видны резкие изменения среднесуточной температуры по отношению к соседним дням. Это можно объяснить солнечной тёплой погодой, или же наоборот резким падением среднесуточной температуры летом из-за дождей и пасмурной погоды.

## ПОСТРОЕНИЕ МОДЕЛИ

Все рассматриваемые нейронные сети (далее модели) имели один скрытый слой с сигмоидальной функцией активации, которая имеет вид:

$$f(x) = \frac{2}{1 + e^{-2x}} - 1.$$

Рассматривалось множество моделей с одним и двумя скрытыми слоями. Количество нейронов каждого скрытого слоя варьировалось от 2-х до 50.

Модели обучались с помощью алгоритма сопряжённого градиента, и среди них выбиралась лучшая.

Далее будут описаны этапы построения моделей.

## Отбор признаков

Сеть для почасового прогнозирования объёма энергии имеет один выход, который выдаёт прогноз объёма энергии на следующий период.

В качестве признаков подаются: история нагрузок, 7 блоков температур и блок входов с текущим временем.

Определение количества предыдущих значений, которые необходимо подавать на вход сети, для каждого из 11 температурных рядов и 20 рядов потребления энергии определялось независимо с помощью корреляционного критерия. При этом были исключены из рассмотрения четыре температурных ряда из-за сильной зашумлённости.

**История нагрузок.** На данный блок входов для каждого из двадцати рядов нагрузок, подавались нормированные значения с часовыми лагами с первого по шестой включительно, а также двенадцатый и двадцать четвёртый лаг. Другими словами, если мы хотим спрогнозировать  $y_t$ , то на вход нужно подавать  $x_{t-1} \dots x_{t-6}, x_{t-12}, x_{t-24}$ .

**Температуры.** На данный блок входов подавались нормированные значения температур с семи станций со следующими часовыми лагами: первый, третий, четвёртый и двадцать четвёртый.

Блок входов нейронной сети, на которые подавалось время, состоит из трёх подблоков: времени суток, дней недели и месяцев.

Сначала время представлялось одним входом в виде нарастающей линейной функции. При этом, например, для полуночи понедельника данные кодировались как 0, а полночь субботы кодировалась значением 7. Недостатком такого подхода является наличие резких перепадов значений кодов между воскресеньем («7») и следующим понедельником («0»). Обучение моделей показало, что такой подход приводил к большим ошибкам прогноза в момент этого перехода в связи с тем, что близкие по сути сущности, такие как воскресенье и понедельник, кодировались экстремальными значениями интервала (7 и 0 соответственно), что приводило к скачку ошибки на границе интервала.

Для устранения этого эффекта было принято решение представить каждый временной вход двумя независимыми входами. Один из этих входов представляет косинус, а второй синус от данной переменной. Формула преобразования имеет вид:

$$Us(x) = \sin\left(\frac{2\pi x}{L}\right), \quad Uc(x) = \cos\left(\frac{2\pi x}{L}\right),$$

где  $L = \max\{x\} - \min\{x\}$ , для переменной, которая кодирует дни недели  $L = 7$ ;  $x$  — временная переменная, которая принимает значения от 0 до 7 для дней недели и от 0 до 24 для суточного времени.

Два входа для каждой переменной необходимы для того, чтобы в любой точке однозначно вычислить значение временной переменной, что становится возможным благодаря сдвигу фаз. Такое преобразование позволило избежать резких скачков ошибки и значительно улучшило прогноз. Введение двойного кодирования блока временных переменных в виде косинуса и синуса уменьшило среднюю ошибку прогнозирования на 3,6%.

Кроме того, в модели был произведён учёт отдельных факторов, таких как праздничные дни. Было выявлено, что потребление в праздничные дни качественно отличается от потребления энергии в обычные дни. На рис. 3 изображён график ошибки между прогнозируемыми и действительными значениями нагрузки в новогодний период. По оси абсцисс отложено время в часах, а по оси ординат — абсолютные значения ошибки.

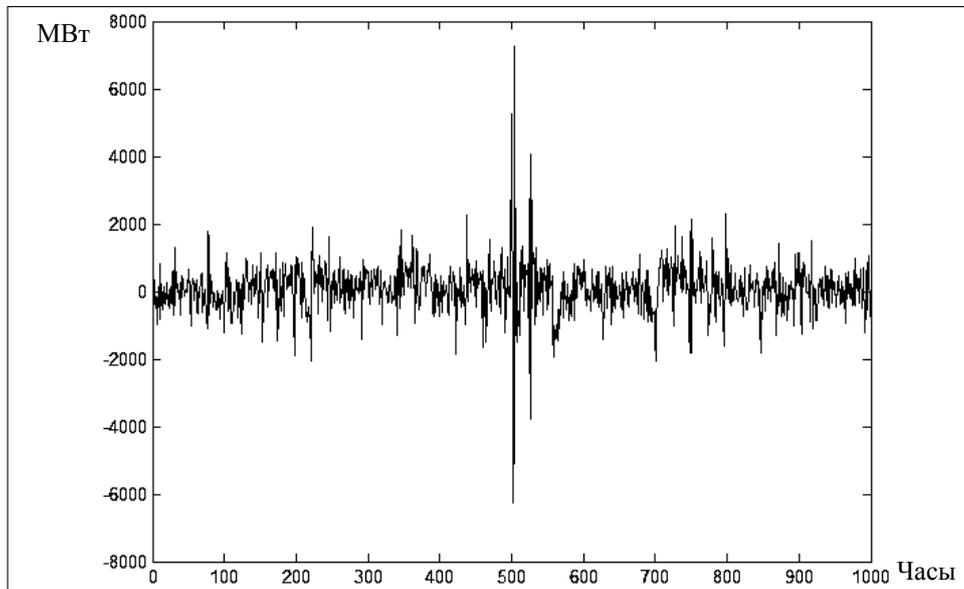


Рис. 3. График ошибки прогнозирования на не участвовавшей в обучении части выборки (новогодний период)

График построен таким образом, что мы учитываем 500 часов до и 500 после нового года. Из графика видно, что в новогоднюю ночь, в районе 500-го отсчёта, наблюдается резкий скачок ошибки. Это означает, что текущее представление информативных признаков, подаваемое на сеть, является неполным. Чтобы исправить положение, был добавлен отдельный информационный вход, на который подавалась «+1» в новогодний период и «-1» во всё остальное время.

После переобучения модели график ошибок стал выглядеть так, как показано на рис. 4 (оси такие же, как и на рис. 3).

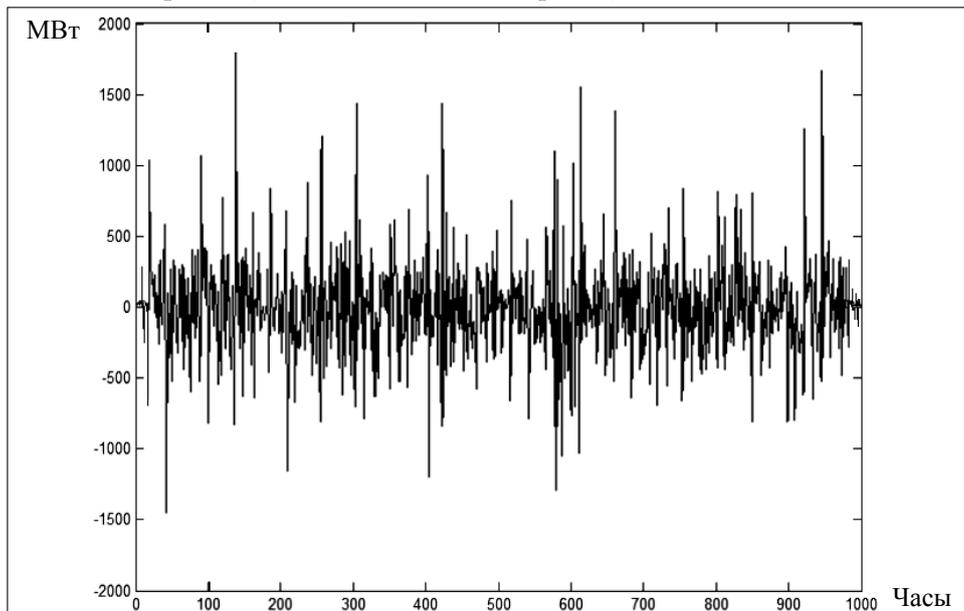


Рис. 4. График ошибки прогнозирования за тот же период, после добавления дополнительного информационного входа

Как видно из графика на рис. 4, при введении новых входов, эффект большой ошибки в новогоднюю ночь снят. Теперь ошибка не превосходит 25 % от предыдущего значения, но на графике всё ещё присутствуют регулярные пики, которые могут отвечать за другие неучтённые события. Над выявлением причин данных событий и будет продолжаться работа.

### Способ и критерии обучения

Для обучения, вся выборка делилась на три части: обучающую (Training), тестировочную (Test) и валидационную (Validation) в соотношении: 70% – 15% – 15%. Все входящие сигналы независимо нормировались в диапазоне от «-1» до «1», чтобы избежать разного влияния разброса разнотипных данных.

Сеть обучалась методом сопряжённых градиентов по критерию минимизации среднеквадратической ошибки (MSE) — алгоритмом обратного распространения ошибки в среде Матлаб.

Для избегания переобучения использовался критерий раннего останова — как только ошибка на тестировочной выборке достигала минимума — обучение прекращалось.

Графики регрессии для данных трёх подвыборок имеют вид, представленный на рис. 5.

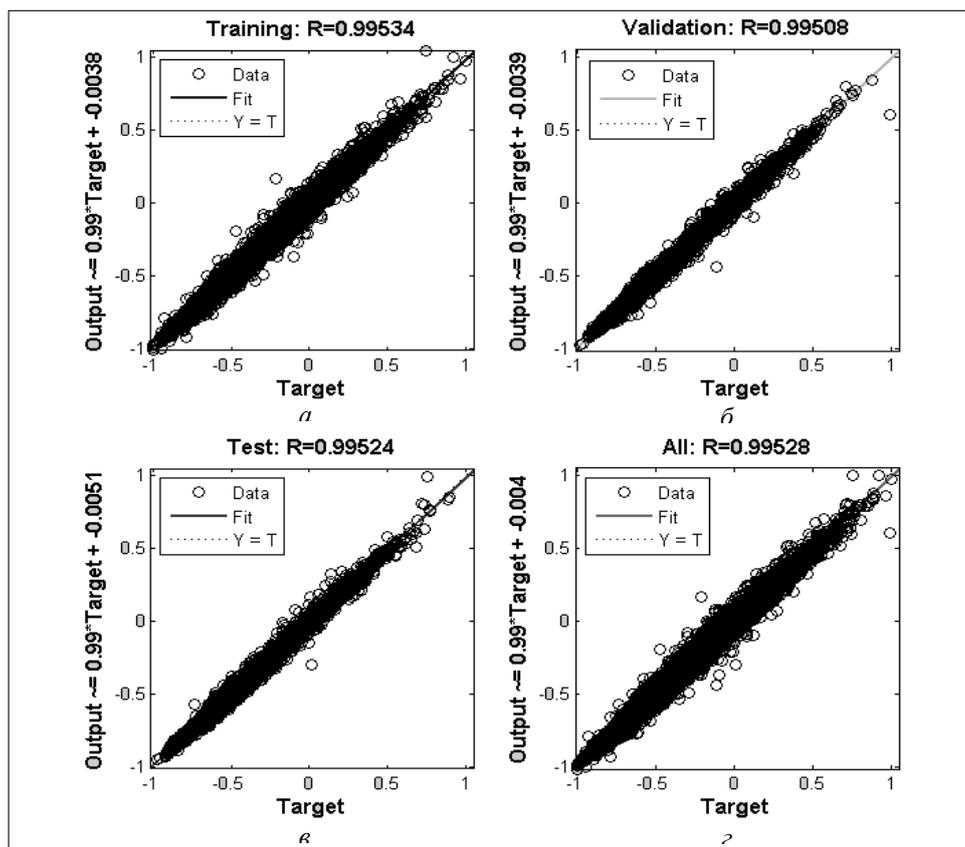


Рис. 5. Графики регрессии: *a* — регрессия на обучающей подвыборке (Training); *б* — регрессия на тестировочной подвыборке (Test); *в* — регрессия на валидационной подвыборке (Validation); *г* — сводный график регрессии на всей выборке

Четвёртый график (All) — сводный по всей выборке. На данных графиках, каждая точка имеет следующие координаты: прогнозируемые значения на оси ординат, а действительные — на оси абсцисс. При этом, чем ближе точки лежат к прямой  $x = y$ , тем лучше полученный результат.

Как видно из графика по виду регрессии у нас наблюдается хорошая корреляция, про что также свидетельствует значение критерия  $R = 0,99528$ .

На обучающей и на валидационной подвыборке были получены следующие оценки (таблица):

**Т а б л и ц а .** Результаты тестов

Критерии \ Подвыборки	Train Set	Validation Set
MSE	312580,138	385422,920
STD	559,089	617,719
MAPE	0,0105	0,0117

В таблице MSE — среднеквадратическая ошибка, STD — среднеквадратическое отклонение, MAPE — средняя абсолютная процентная ошибка. Как видим из небольшого отличия критериев на двух независимых выборках, сеть хорошо уловила зависимость и переобучение не наблюдается.

На рис. 6 показан график спрогнозированной потребляемой энергии, где ось аппликат — мегаватты, прогноз на 60 дней в режиме от 0 до 24 часа.

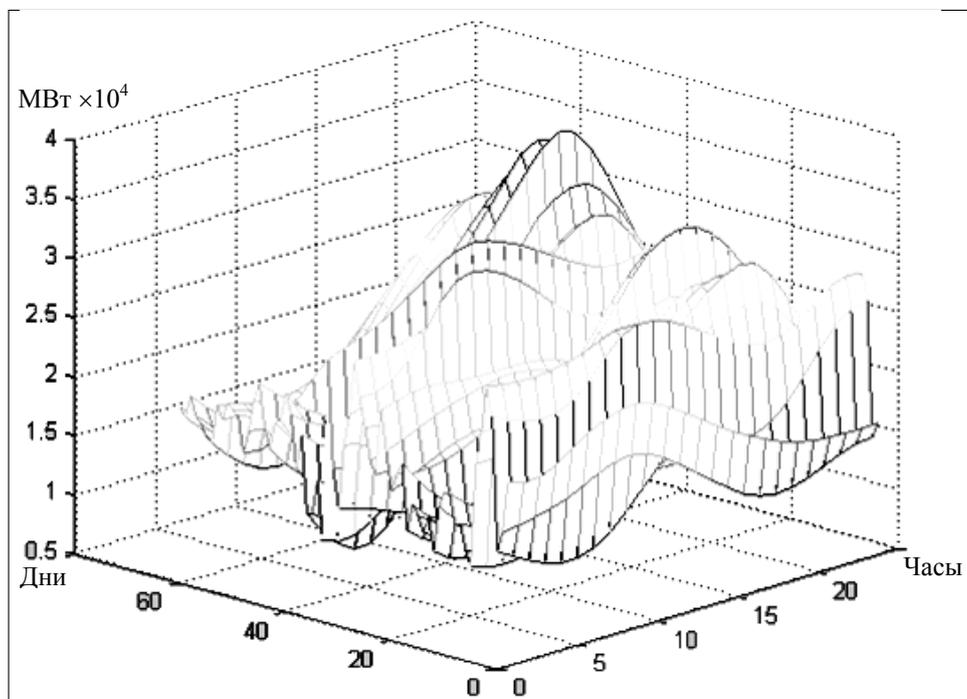


Рис. 6. Конечный вид прогнозируемых значений объёма энергии

## ВЫВОДЫ

В данной работе было рассмотрено построение и выбор параметров нейронной сети для прогнозирования потребления электроэнергии. Были получены МАРЕ от 0,0105 до 0,0117 на обучающей и независимой валидационной выборках соответственно. Введение двойного кодирования блока временных переменных в виде косинуса и синуса уменьшило среднюю ошибку прогнозирования на 3,6%.

Оптимальное количество нейронов скрытого слоя было определено равным семи. При этом, сети даже с тремя нейронами давали результат со значением ошибки МАРЕ не более 5%. Были замечены непропорционально большие ошибки прогноза на праздничные дни, что было исправлено путём ввода в модель входов-индикаторов, которые указывают на то, является ли данный день праздником.

Таким образом, проведённая работа позволяет ОРЭ получать более точные суточные прогнозы потребления энергии, что позволит более качественно осуществлять управление энергосетью. Достоинством данного подхода также является то, что количество нейронов в полученных сетях невелико, что позволяет производить расчёты прогнозов даже на маломощной вычислительной технике.

## ЛИТЕРАТУРА

1. *Fan Z., Kulkarni P., Gormus S.* Smart Grid Communications: Overview of Research Challenges, Solutions, and Standardization Activities. — <http://arxiv.org/abs/1112.3516>.
2. *Galli S., Scaglione A., Wang Z.* For the Grid and Through the Grid: The Role of Power Line Communications in the Smart Grid. — <http://arxiv.org/abs/1010.1973>.
3. *Сайт ДП «Енергоринок».* — <http://er.gov.ua>.
4. *Lin J.* Strategen, Advanced Energy Storage, i4Energy seminar: i4Energy Center Initiative. — <http://www.youtube.com/watch?v=h2iyQcXQUSw>.
5. *A hierarchical load forecasting problem: backcasting and forecasting hourly loads (in kW) for a US utility with 20 zones.* — <http://www.kaggle.com/c/global-energy-forecasting-competition-2012-load-forecasting>.

Поступила 19.07.2014