

Васильев Г.В., Бердонос В.Д.

Комсомольский-на-Амуре государственный университет

МЕТОДИКА ПО ЭФФЕКТИВНОМУ ПРИМЕНЕНИЮ ГИБРИДНЫХ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ

Планирование энергосистемы отвечает за производство, передачу и распределение электроэнергии. Таким образом, точный прогноз потребления электроэнергии имеет важное значение, поскольку он служит основой для управления энергопотреблением и оперативных решений. Это стало бы большим шагом вперед для производителей энергии. Кроме того, усовершенствованная обработка данных об энергии открывает новые возможности для сбора данных, их изучения, а также для более точного прогнозирования. В результате исследователи во всем мире предпринимают попытки повысить прогнозы спроса на энергию. Поэтому энергетическим компаниям необходимо исследовать модели, чтобы лучше прогнозировать и планировать использование энергии. Одним из подходов к решению этой проблемы является оценка потребления энергии на уровне потребителя. Задача прогнозирования энергопотребления представляет собой задачу регрессии временных рядов. Она состоит в прогнозировании потребления энергии на следующие несколько дней с учетом конечной истории клиента. Методы машинного обучения показали многообещающие результаты в различных задачах, включая задачи временных рядов и регрессии. Часть этих многообещающих результатов связана с глубокими нейронными сетями. Хотя глубокие архитектуры моделей исследовались в других областях, они не использовались для решения проблемы прогнозирования энергопотребления. В этой работе предлагается новая эффективная система для прогнозирования ежемесячного потребления энергии с использованием методов глубокого обучения. Авторы проанализировали две модели машинного обучения, разработали несколько архитектур моделей нейронных сетей. Исследование моделей проводилось на наборе данных, который включал в себя исторические данные за 10 лет. Результаты показали, что итоговая архитектура гибридной модели может прогнозировать ежечасное потребление энергии с относительной ошибкой 5%. Предлагаемое решение могло бы подействовать на производителей/распределителей энергии в качестве помощи интеллектуальным счетчикам для принятия более эффективных решений по сокращению общего потребления энергии за счет ограничения производства энергии.

Ключевые слова: машинное обучение, нейронные сети, XGBoost, LSTM, RNN, CNN, прогнозирование энергопотребления, временные ряды, энергетика

ВВЕДЕНИЕ

По мере того, как с годами росли наши города, росла и наша зависимость от энергии для обеспечения комфортных условий для нахождения в здании. Потребление энергии в жилом секторе резко возросло в последние годы, в основном из-за роста населения и потребности в увеличении жилых и коммерческих площадей.

Сейчас мир стремится к сокращению выбросов. Текущие технологии дают возможность для повышения энергоэффективности. Когда дело доходит до зданий, вопрос энергоэффективности вызывает огромную озабоченность у владельцев и управляющих недвижимостью, так как это является частью их расходов. Поскольку такая огромная часть энергоснабжения идет на коммерческие здания, такие как школы и офисы, которые люди часто посещают ежедневно, легко понять, сколько денег и энергии можно сэкономить, если наши здания будут максимально эффективными. Так уж получилось, что лучшая стратегия для достижения энергоэффективности в зданиях – это так называемое «прогнозирование». Энергетическое прогнозирование – это практика использования статистических данных для прогнозирования уровней потребления и соответствующих расходов на коммунальные услуги как в краткосрочной, так и в долгосрочной перспективе.

С ростом исследований в области энергоэффективности зданий и разработки решений прогнозирование энергопотребления зданий набирает обороты. Благодаря достижениям в развитии датчиков и программ-

ного обеспечения мы теперь можем предсказывать ее. Стратегически потребляя энергию на основе прогнозов использования и внешних условий, здания могут быть более прибыльными. Прогнозирование энергопотребления здания может служить инструментом предварительной оценки для управляющих объектами и систем автоматизации зданий для выявления любых различий между прогнозируемым и фактическим энергопотреблением. Чтобы прогнозировать спрос на энергию, руководители объектов и проекты по вводу в эксплуатацию зданий используют точные прогнозы энергопотребления для принятия стратегий энергосбережения и улучшения работы чиллеров, бойлеров, накопителей энергии и т.п.

Главная задача – это предсказать, как потребители будут использовать энергию, а затем соответствующим образом организовать работу коммунальных служб. И также учитывать новые элементы, такие как программное обеспечение для управления энергопотреблением, и заботу о перезарядке электромобилей.

Авторы провели анализ моделей машинного обучения [1], нейронных сетей [1-3, 5] и гибридных моделей искусственного интеллекта [2, 6-9], таких как XGBoost [10], RNN [4, 11], LSTM [2, 12-18], CNN [19], которые применяются в разных сферах. Изучили работу с временными рядами [1, 20-28].

АКТУАЛЬНОСТЬ

Чрезвычайная ситуация со спросом на электроэнергию усугубляется недавним сильным экономическим развитием и быстрой урбанизацией. Прогнозирование спроса на электроэнергию становится критиче-

ски важным в электроэнергетическом секторе, поскольку оно служит основой для принятия важных решений в области эксплуатации и управления энергосистемой.

Ценообразование на энергию в значительной степени зависит от экономики спроса и предложения. В идеальном мире, по крайней мере в контексте традиционной энергосистемы, которая непрерывно генерирует и распределяет электроэнергию, нам потребуется одинаковое количество энергии в течение дня. К сожалению, это не так. Каждый день спрос на электроэнергию чередуется с периодами низкого и высокого спроса. Рано утром, когда большинство людей еще не встали с постели, потребление электроэнергии относительно невелико. Но во время дневной суеты, когда большинство людей включают свет, берутся с термостатами или печатают на своих компьютерах, потребность в электроэнергии резко возрастает. Колебания спроса на электроэнергию также зависят от того, какой сейчас день недели. Потребление энергии в праздничные и выходные дни обычно намного меньше по сравнению с потреблением энергии в обычный будний день, поскольку многие предприятия закрыты и, следовательно, им не требуется столько энергии.

Прогнозирование потребления электроэнергии считается проблемой временного ряда, в котором датчики производят данные с неопределенностями, избыточностью, пропущенными значениями и т. д.

С появлением машинного обучения становится все более возможным точное прогнозирование будущего энергопотребления. Точные прогнозы дают двойную выгоду: во-первых, менеджеры получают ключевое представление о факторах, влияющих на потребление энергии их зданием, предоставляя возможности для их устранения и повышения энергоэффективности. Во-вторых, прогнозы служат эталоном для выявления аномально высокого/низкого энергопотребления и предупреждают менеджеров о неисправностях в здании.

Обычные методы машинного обучения изо всех сил пытаются надежно прогнозировать использование энергии из-за неустойчивых элементов поведения или сезонных тенденций. Трудность заключается в нелинейности и изменчивости потребления энергии в реальном времени, которое очень чувствительно к изменениям внешних факторов. Например, известно, что температура окружающей среды значительно влияет на потребность здания в энергии через отопление и кондиционирование воздуха.

Соответствие потребления электроэнергии правильному уровню снабжения имеет решающее значение, поскольку избыточное количество поставляемой электроэнергии невозможно сохранить, если только оно не будет преобразовано в другие формы, что влечет за собой дополнительные затраты и ресурсы. В то же время недооценка энергопотребления может иметь фатальные последствия, поскольку избыточный спрос может привести к перегрузке линии снабжения и даже к отключению электроэнергии. Очевидно, что тщательный мониторинг энергопотребления зданий – будь то офисные, коммерческие или бытовые – дает ощутимые преимущества.

МЕТОДИКА

Сформулируем задачу прогнозирования электропотребления заданного географического района в виде задачи регрессии временного ряда.

Задача решается на ближайшие 3 дня. Эта установка оправдана экономической и управленческой ценностью ожидаемого объема производства – легко спланировать энергоснабжение на следующую неделю, имея прогнозируемый спрос на потребление энергии.

Потребление электроэнергии измеряется в Вт·ч. С точки зрения электромагнетизма один ватт – это скорость, с которой выполняется работа.

В целом предлагаемое техническое решение включает следующие шаги:

- Шаг 1 – предварительная обработка данных [29].
- Шаг 2 – разработка модели.
- Шаг 3 – оценка модели.

Шаг 1: предварительная обработка данных

Для проверки гипотезы и моделей был выбран набор данных, который находится в свободном доступе. Этот набор данных содержит более 10 лет данных о почасовом потреблении энергии от PJM в мегаваттах.

PJM Interconnection LLC – региональная передающая организация в США. Она является частью сети Eastern Interconnection, управляющей системой электропередачи, обслуживающей все или некоторые штаты Делавэр, Иллинойс, Индиана, Кентукки, Мэриленд, Мичиган, Нью-Джерси, Северная Каролина, Огайо, Пенсильвания, Теннесси, Вирджиния.

Во время анализа набора данных были решены несколько проблем, а именно:

- сортировка данных по дате и времени;
- удаление дубликатов.

Шаг 2: разработка модели

Для сравнения моделей результаты будут представлены в виде графика, где синей линией будут показаны реальные значения ежечасного потребления энергии, а зеленой линией показаны прогнозируемые значения.

Prophet – это процедура прогнозирования данных временных рядов на основе аддитивной модели, в которой нелинейные тренды соответствуют годовой, еженедельной и ежедневной сезонности. Он лучше всего работает с временными рядами, которые имеют сильные сезонные эффекты и несколько сезонов исторических данных. Prophet устойчив к отсутствующим данным и сдвигам в тренде и обычно хорошо справляется с выбросами. Prophet является программным обеспечением с открытым исходным кодом, выпущенным командой американских разработчиков. Результат обучения представлен на **рис. 1**.

Extreme Gradient Boosting (XGBoost) – это библиотека с открытым исходным кодом, которая обеспечивает эффективную и действенную реализацию алгоритма повышения градиента. Проблемы регрессионного прогнозного моделирования включают прогнозирование числового значения, такого как курс доллара. XGBoost можно использовать непосредственно для прогнозного регрессионного моделирования. Результат обучения представлен на **рис. 2**.




Рис. 1. Результаты обучения на модели Prophet




Рис. 2. Результаты обучения на модели XGBRegressor

LSTM. Сети с долговременной кратковременной памятью, представляют собой особый вид рекуррентной нейронной сети, способный изучать долгосрочные зависимости. LSTM специально разработана, чтобы избежать проблемы долгосрочной зависимости. Запоминание информации в течение длительного периода времени практически является их поведением по умолчанию. LSTM имеет возможность удалять или добавлять информацию в состояние ячейки, тщательно регулируемую структурами, называемыми воротами. Ворота – это способ опционального пропуска информации. Они состоят из слоя сигмовидной нейронной сети и операции поточечного умножения. Результат обучения представлен на рис. 3.

Multi-layer LSTM. Модель состоит из трех слоев LSTM. Это обеспечивается следующим путем. Каждая ячейка памяти LSTM требует ввода матрицы. Когда LSTM обрабатывает одну входную последовательность временных шагов, каждая ячейка памяти будет выводить одно значение для всей последовательности в виде двумерного массива. Чтобы сложить слои LSTM, была изменена конфигурация предыдущих слоев LSTM, чтобы вывести матрицу в качестве входных данных для последующего слоя. Результат обучения представлен на рис. 4.

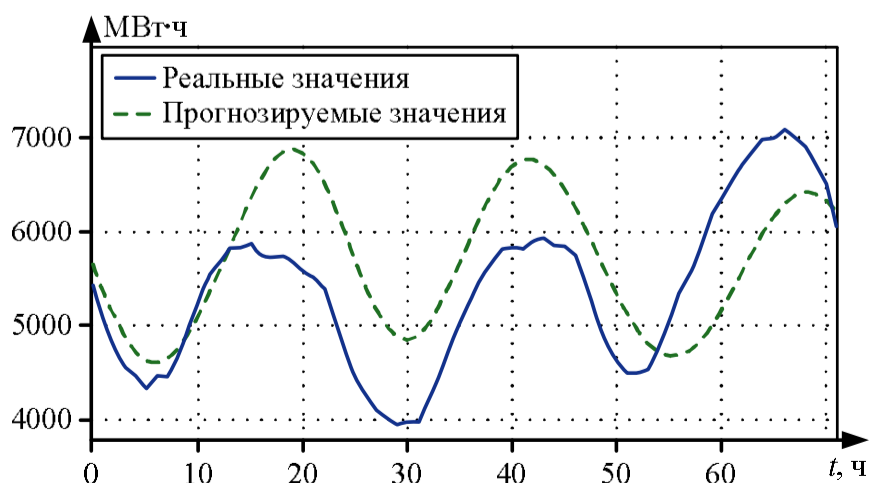


Рис. 3. Результаты обучения на модели LSTM




Рис. 4. Результаты обучения на модели Multi-layer LSTM

Bidirectional LSTM. Двухнаправленная долговременная память – это процесс, при котором любая нейронная сеть получает информацию о последовательности в обоих направлениях назад (из будущего в прошлое) или вперед (из прошлого в будущее). В двухнаправленном режиме наш ввод течет в двух направлениях, что отличает Bidirectional LSTM от обычного LSTM. С помощью обычного LSTM мы можем сделать поток ввода в одном направлении, либо назад, либо вперед. Однако в двухнаправленном режиме мы можем сделать входной поток в обоих направлениях, чтобы сохранить будущую и прошлую информацию. Результат обучения представлен на рис. 5.

Conv + LSTM. Одномерный слой свертки (например, временная свертка). Этот слой создает ядро свертки, которое сворачивается с входными данными слоя в одном пространственном (или временном) измерении для создания тензора выходных данных. Преимущества данной гибридной модели следующие. Слой Conv1D сглаживают входные временные ряды, поэтому нам не нужно добавлять значения скользящего среднего или скользящего стандартного отклонения во входные функции. Результат обучения представлен на рис. 6.

TimeDistributed Conv + LSTM. Эта оболочка позволяет применять слой к каждому временному срезу ввода. Измерение индекса первого входа будет считаться временным измерением. Результат обучения представлен на рис. 7.

Модель TimeDistributed Conv + Bidirectional LSTM + LSTM. Модель объединяет вышеописанные архитектуры. Результат обучения представлен на рис. 8, а.

ConvLSTM2D. Подобно LSTM, но входные преобразования и рекуррентные преобразования являются сверточными. Вместо умножения матриц модель выполняет операции свертки и сохраняет входные размеры. Результат обучения представлен на рис. 8, б.




Рис. 5. Результаты обучения на модели Bidirectional LSTM

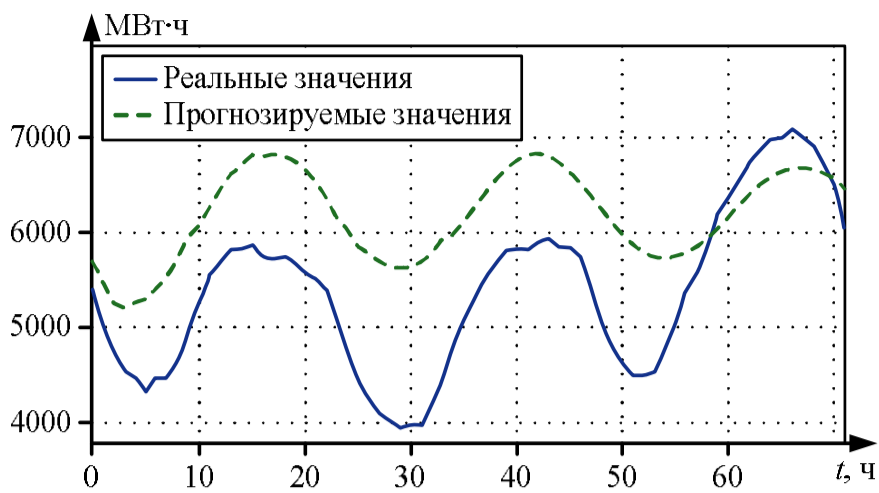


Рис. 6. Результаты обучения на модели Conv + LSTM




Рис. 7. Результаты обучения на модели TimeDistributed Conv + LSTM


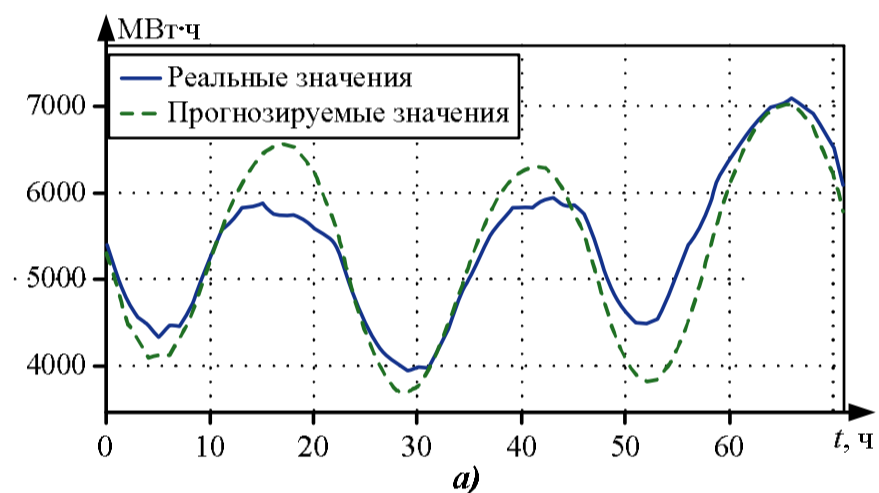


Рис. 8. Результаты обучения на модели TimeDistributed Conv + Bidirectional LSTM + LSTM (а) и ConvLSTM2D (б)

Шаг 3: Оценка модели

Для нейронных сетей функция активации была выбрана ReLU (Rectified Linear Unit).

Выпрямленная линейная функция активации – это нелинейная функция или кусочно-линейная функция, которая будет выводить входные данные напрямую, если она положительна, в противном случае она будет выводить ноль. Функция более эффективна, чем ее предшественники, такие как sigmoid или tanh.

Математически это выражается как:

$$f(x) = \max(0, x).$$

ReLU используется в скрытых слоях вместо sigmoid или tanh, поскольку использование sigmoid или tanh в скрытых слоях приводит к печально известной проблеме «исчезающего градиента». «Исчезающий градиент» предотвращает получение важной информации более ранними слоями при обратном распространении сети. Сигмовидную функцию, которая является логистической функцией, предпочтительнее использовать в задачах, связанных с бинарной классификацией, и только в выходном слое, поскольку выходные данные сигмовидной функции колеблются от 0 до 1.

Преимущества ReLU:

- Более простые вычисления: производная остается постоянной, то есть 1 для положительного входа, и, таким образом, сокращает время, необходимое для обучения модели и минимизации ошибок.

- Репрезентативная разреженность: функция способна выводить истинное нулевое значение.

- Линейность: функции линейной активации легче оптимизировать и они обеспечивают плавный поток. Таким образом, функция лучше всего подходит для контролируемых задач на больших наборах размеченных данных.

Функция потерь была выбрана MSE. Среднеквадратическая ошибка (Mean Squared Error – MSE) измеряет количество ошибок в статистических моделях. Она оценивает среднюю квадратичную разницу между наблюдаемыми и прогнозируемыми значениями. Когда модель не имеет ошибок, MSE равняется нулю. По мере увеличения ошибки модели ее значение увеличивается. Среднеквадратическая ошибка также известна как среднеквадратичное отклонение (Mean Squared Deviation - MSD).

В регрессии среднеквадратическая ошибка представляет собой среднеквадратичную невязку. В статистических моделях невязка – это разница между наблюдаемым значением и средним значением, которое модель предсказывает для этого наблюдения. Остаточные значения особенно полезны в процедурах регрессии и дисперсионного анализа, поскольку они показывают степень, в которой модель учитывает вариации наблюдаемых данных.

По мере того как точки данных приближаются к линии регрессии, модель имеет меньшую ошибку, уменьшая MSE. Модель с меньшей ошибкой дает более точные прогнозы.

Формула для MSE следующая:

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n},$$

где y_i – наблюдаемое значение; \hat{y}_i – соответствующее прогнозируемое значение; n – количество наблюдений.

Вычисления среднеквадратичной ошибки аналогичны дисперсии.

MSE представляет собой средний квадрат расстояния между наблюдаемыми и прогнозируемыми значениями. Поскольку в нем используются квадратные единицы, а не натуральные единицы данных, интерпретация менее интуитивна. Возведение разностей в квадрат устраняет отрицательные значения разностей и гарантирует, что среднеквадратическая ошибка всегда больше или равна нулю. Это почти всегда положительное значение. Кроме того, возведение в квадрат

увеличивает влияние больших ошибок. Эти расчеты непропорционально наказывают большие ошибки больше, чем меньшие ошибки.

Среднеквадратичную ошибку RMSE (Root Mean Square Error – RMSE) и среднюю абсолютную ошибку MAE (Mean Absolute Error) авторы также учитывали в процессе обучения. Формула RMSE следующая:

$$RMSE = \sqrt{MSE}.$$

RMSE аналогичен стандартному отклонению.

MAE – это функция потерь, используемая для регрессии. Потери – это средние наблюдаемые данные абсолютных разностей между истинными и прогнозируемыми значениями. MAE определяется по формуле:

$$MAE = \frac{\sum |y_i - \hat{y}_i|}{n}.$$

Относительное отклонение являлось ключевой метрикой. Дополнительными метриками было время обучения и абсолютное отклонение.

ЭКСПЕРИМЕНТАЛЬНЫЕ РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для экспериментов каждой модели была поставлена задача спрогнозировать потребление энергии на 3 дня вперед. Авторы составили план экспериментов, в котором установили контрольные значения: время обучения 15 мин; абсолютная ошибка 500 МВт·ч; относительная ошибка 10%.

Эксперименты проводились на следующем техническом оборудовании:

- CPU AMD Ryzen 9 5900HX.
- GPU GeForce RTX 3060 6 Гб, 100 Вт, ~3840 CUDA ядер.
- RAM 32 Гб, 3200 МГц.

В ходе исследований было выявлено, что машинное обучение хорошо справляется со структурированными данными. Тем не менее авторы смогли разработать архитектуру нейронной сети, которая выполняла контрольные значения.

После проведения ряда экспериментов авторы выбрали последнюю разработанную архитектуру гибридной нейронной сети. Модель принимает массив данных, после чего для каждого значения из массива получает ряд значений на N шагов назад. То есть, если исходными данными будет массив $Y = [1434,0 \ 1489,0 \ 1620,0]$, то для обучения модели получаем матрицу:

$$X = \begin{bmatrix} 1621,0 & 1536,0 & 1500,0 \\ 1536,0 & 1500,0 & 1434,0 \\ 1500,0 & 1434,0 & 1489,0 \end{bmatrix},$$

где первая строка «1621,0 1536,0 1500,0» является значениями на 3 шага назад – от 1434,0 и т.д.

Для прогнозирования более 3 дней реализован алгоритм, который считывает прогнозируемые значения с выхода гибридной модели. Далее полученные значения подставляются в текущий набор данных и отправляются на обучения и т.д. Если запустить алгоритм на прогнозирование ежечасного потребления электроэнергии на 6 дней вперед, то модель принимает временной ряд, обучается и выдает прогноз на 3 дня вперед, после чего этот

прогноз объединяет с входным варенным рядом (dataset – набор данных) и обучается повторно, после чего снова выдает прогноз на 3 дня вперед. Тем самым получаем уже прогноз на 6 дней вперед.

Для оптимизации работы гибридной модели были вынесены следующие параметры: количество скрытых слоев и количество шагов.

Для избегания переобучения нейронной сети реализована функция, которая принимает аргументом минимально допустимое значение ошибки. Помимо этого, еще сохраняются веса модели. Таким образом, если следующий цикл обучения будет хуже, чем предыдущий, то для прогнозирования будет использоваться предыдущий файл с весами.

Для решения проблем с изменением климата авторы реализовали лямбду-архитектуру. Процесс разделен на два потока. Первый поток «долгий». Модель прогнозирует значения энергопотребления на год вперед на основе набора данных, состоящих из показателей энергии за несколько лет. Такой объем вычислений выполняется не быстро.

Второй поток «быстрый». Он выполняется на существенно меньшем объеме данных и прогнозирует потребление энергии на месяц вперед. Данный поток выполняется намного быстрее, чем первый поток процесса. Таким образом, второй поток «быстрый», с большей вероятностью учтет изменения климата, так как объем данных будет невелик. То есть в наборе данных будут входить все значения с уже измененным климатом, а исторические данные с далеким прошлым, где климат был другой, не будут присутствовать. В итоге, когда первый поток «долгий» завершится, происходит корректировка данных относительно результатов с «быстрого» потока. Если отклонения выше порогового значения между двумя результатами «быстрого» и «медленного» потока, то взять средние или более точные данные с одного или другого потока.

ЗАКЛЮЧЕНИЕ

Когда дело доходит до оптимизации управления зданием, прогнозирование позволяет руководителям объектов планировать определенные задачи так, чтобы они совпадали с часами пиковой или непииковой нагрузки, что позволит максимально равномерно распределить потребление энергии в течение дня. Это стратегическое планирование снижает энергетическую нагрузку в час пик, когда электроэнергия является наиболее дорогой, снижая затраты на электроэнергию и обеспечивая максимальную экономию. Прогнозирование энергопотребления уникально для каждого здания из-за таких факторов, как географическое положение (поскольку расстояние от источника питания напрямую влияет на затраты на электроэнергию), текущие погодные условия за пределами здания и функция здания (независимо от того, является ли оно офисным зданием, торговая площадь, многоквартирный дом и др.). Таким образом, управляющие объектами должны проявлять инициативу в прогнозировании энергопотребления, чтобы разработать наиболее эффективный способ максимизировать свои финансовые сбережения, а также снизить свой углеродный след.

Прогноз потребления электроэнергии имеет решающее значение в функционировании энергосистемы, а обработка временных рядов представляет собой сложную задачу.

Сильные стороны искусственной нейронной сети (ИНС) включают явный прирост производительности по сравнению с обычными методами машинного обучения. Однако компромиссом для такого повышения производительности является то, что требуются большие объемы данных (проклятие размерности), и, таким образом, вычислительные затраты могут стать большими как во времени, так и в денежном аспекте. Внутренняя работа того, как учится ИНС, также остается «черным ящиком».

В заключение авторы построили точную гибридную модель нейронной сети для прогнозирования энергопотребления на несколько дней вперед. Модель превысила контрольную ключевую метрику «относительная ошибка» в два раза, а дополнительная метрика «время обучения» была удовлетворена. Тем самым обеспечивая благоприятные условия использования. Таким образом, затраты временных и денежных ресурсов будут небольшими.

СПИСОК ИСТОЧНИКОВ

1. Kitov V.V., Mishustina M.V., Ustyuzhanin A.O. Time series prediction survey of statistical, machine learning and deep learning methods: historical aspects // Вопросы истории. 2022. № 4-2. С. 201-218. doi: 10.31166/VoprosyIstorii202204Statyi40
2. Berdonosov V.D., Vasilev G.V., Zhivotova A.A. Analysis and development potential of predictive models for energy flows of autonomous hybrid energy systems // Journal of physics: conference series. 2021. Vol. 2096. 012024. doi: 10.1088/1742-6596/2096/1/012024
3. Исследование и применение архитектур глубоких нейронных сетей для классификации на многомерных временных рядах / А.С. Есенков, Е.М. Захарова, М.Д. Ковалева, Д.Е. Константинов, И.С. Макаров, Е.А. Панковец // Известия российской академии наук. Теория и системы управления. 2022. № 4. С. 133-142. doi: 10.31857/s0002338822040072
4. Васильев Г.В., Бердонос В.Д. Разработка и сравнение моделей прогнозирования потребления электроэнергии с помощью рекуррентных нейросетей с долгой краткосрочной памятью // Наука, инновации и технологии: от идей к внедрению: материалы Международной научно-практической конференции. Комсомольск-на-Амуре, 2022. С. 203-206.
5. Васильев Г.В., Бердонос В.Д. Анализ моделей потоков энергий гибридных энергетических систем // Актуальные проблемы информационно-телекоммуникационных технологий и математического моделирования в современной науке и промышленности: материалы I Международной научно-практической конференции молодых учёных. Комсомольск-на-Амуре, 2022. С. 191-194. doi: 10.17084/978-5-7765-1488-3-2021-191
6. Deep CNN-LSTM-based dstatcom for power quality enhancement in microgrid / P. Kandasamy, K. Chandrasekaran, R. Natarajan, J. Selvaraj // Journal of circuits, systems, and computers. 2022. Vol. 31. No. 7. 2250130. doi: 10.1142/S0218126622501304
7. Enterprise economic forecasting method based on ARIMA-LSTM model / X. Dong, X. Zong, J. Wang, P. Li // Lecture notes of the institute for computer sciences, social-informatics and telecommunications engineering. 2022. Vol. 429. Pp 36-57. doi: 10.1007/978-3-030-99188-3_4
8. Sentinel-1 spatiotemporal simulation using convolutional LSTM for flood mapping / N.I. Ulloa, S.H. Chiang, S.H. Yun, R. Furuta // Remote sensing. 2022. Vol. 14. No. 2. 246. doi: 10.3390/rs14020246
9. Automated detection of rehabilitation exercise by stroke patients using 3-layer CNN-LSTM model / Z.U. Rahman, S.I. Ullah, A. Salam, T. Rahman, I. Khan, B. Niazi // Journal of Healthcare Engineering. 2022. Vol. 2022. 1563707. doi: 10.1155/2022/1563707
10. Адаптивные ансамблевые модели для среднесрочного прогнозирования выработки электроэнергии гидроэлектростанциями в изолированных энергосистемах с учетом изменений температуры / М.Х. Сафаралиев, П.В. Матренин, С.А. Дмитриев, Дж.С. Ахьеев, С.Е. Кокин // Электротехнические системы и комплексы. 2022. № 1(54). С. 38-45. doi: 10.18503/2311-8318-2022-1(54)-38-45
11. Zhao B., Li X., Lu X. CAM-RNN: Co-attention model based RNN for video captioning // IEEE Trans. Image Process. 2019. Vol. 28. No. 11. Pp. 5552-5565. doi: 10.1109/TIP.2019.2916757
12. Predicting Alzheimer's disease using LSTM / X. Hong, R. Lin, C. Yang, N. Zeng, C. Cai, J. Gou, J. Yang // IEEE Access. 2019. Vol. 7. Pp. 80893-80901. doi: 10.1109/ACCESS.2019.2919385
13. Алексеев А.О., Антонов В.И. Подтверждение Конфигурации Электрической сети с помощью LSTM-нейронной сети // Информационные технологии в электротехнике и электроэнергетике: материалы XIII Всероссийской научно-технической конференции. Чебоксары, 2022. С. 340-344.
14. Hasoon S.O., Al-Hashimi M.M. Hybrid deep neural network and long short term memory network for predicting of sunspot time series // International Journal of Mathematics and Computer Science. 2022. Vol. 17. No. 3. Pp. 955-967.
15. Мейзер М.В., Северьянова Е.Д. Пример прогнозирования временных рядов с помощью рекуррентной нейронной сети LSTM // Профессиональные коммуникации в научной среде - фактор обеспечения качества исследований: материалы XI Всероссийской научно-практической конференции. Санкт-Петербург, 2022. С. 211-214.
16. Тимофеев А.Г., Лебединская О.Г. Модель применения сверточной нейронной сети (CNN) в сочетании с долговременной памятью (LSTM) прогнозирования цены на нефть в условиях неопределенности // Транспортное дело России. 2022. № 2. С. 54-59. doi: 10.52375/20728689_2022_2_54
17. Истамкулов Х.С. Анализ использования и применения архитектуры LSTM // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. 2022. № 6. С. 77-80. doi: 10.37882/2223-2966.2022.06.16
18. A wind power forecasting model using LSTM optimized by the modified bald eagle search algorithm / W. Tuerxun, L. Guo, C. Xu, H. Guo, Y. Gao, N. Zeng // Energies. 2022. Vol. 15. No. 6. 2031. doi: 10.3390/en15062031
19. Zhao R., Lam K., Lun D.P.K. Enhancement of a CNN-based denoiser based on spatial and spectral analysis // IEEE international conference on image processing (ICIP). Taipei, Taiwan, 2019. Pp. 1124-1128. doi: 10.1109/ICIP.2019.8804295
20. Бахметенко О.А., Елисеева А.А. Разработка алгоритма управления микросетью с возобновляемыми источниками энергии учетом краткосрочных прогнозов выработки и потребления электрической энергии // Электроэнергетика глазами молодежи: материалы XI Международной научно-технической конференции. Ставрополь: Северо-Кавказский федеральный университет, 2020. Т. 2. С. 149-150.
21. Методы определения индивидуального потребления тепловой энергии, реализованные на базе интеллектуальной системы контроля энергоресурсов / Ю.И. Штерн, Я.С. Кожевников, В.А. Медведев, Р.Е. Миронов, И.С. Караваев // Измерительная техника. 2013. № 2. С. 46-50.
22. Слюсарева В.А., Буданцев А.В. Исследование и прогнозирование временных рядов // Актуальные исследования. 2022. № 21 (100). С. 33-37.
23. Context-aware deep model for joint mobility and time prediction / Y. Chen, C. Long, G. Cong, C. Li // Proceedings of the 13th International Conference on Web Search and Data Mining (WSDM). NY, United States, 2020. Pp. 106-114. doi: 10.1145/3336191.3371837
24. Мейзер М.В., Северьянова Е.Д., Мокшин В.В. Пример прогнозирования временных рядов с помощью рекуррентной нейронной сети LSTM // Молодой ученый. 2022. № 9 (404). С. 13-15.

25. Шишков Е.М., Проничев А.В., Савельев А.А. Прогнозирование временных рядов с применением методов машинного обучения на примере графика выдачи мощности электрической станции // Международный научно-исследовательский журнал. 2022. № 2-1 (116). С. 56-60. doi: 10.23670/IRJ.2022.116.2.009
26. Емалетдинова Л.Ю., Кабирова А.Н., Вильданов Н.Р. Нейросетевое моделирование задачи прогнозирования значений временного ряда // Вестник технологического университета. 2022. Т. 25. № 10. С. 101-106. doi: 10.55421/1998-7072_2022_25_10_101
27. Девришев Н.Э., Хэ Ю., Петросян О.Л. Обнаружение аномалий во временных рядах с помощью методов прогнозирования // Процессы управления и устойчивость. 2022. Т. 9. № 1. С. 202-209.
28. Евстигнеев И.П. Прогнозирование временных рядов // Системный администратор. 2022. № 7-8 (236-237). С. 138-139.
29. Тимофеев Г.А., Бердоносков В.Д. Использование актуальных инструментов для сбора и анализа данных // Наука, инновации и технологии: от идей к внедрению: материалы Международной научно-практической конференции. Комсомольск-на-Амуре, 2022. С. 257-258.

Поступила в редакцию 14 сентября 2022 г.

Принята к печати 15 октября 2022 г.

INFORMATION IN ENGLISH

METHODOLOGY FOR EFFECTIVE APPLICATION OF HYBRID MODELS OF NEURAL NETWORKS FOR ENERGY CONSUMPTION PREDICTION

Gordei V. Vasilev

Postgraduate student, Komsomolsk-on-Amur State University, Komsomolsk-on-Amur, Russia, gordeyvasilev@gmail.com, <https://orcid.org/0000-0003-0485-8664>

Viktor D. Berdonosov

Ph.D. (Engineering), Associate Professor, Department of Applied Mathematics, Komsomolsk-on-Amur State University, Komsomolsk-on-Amur, Russia, berd1946@gmail.com, <https://orcid.org/0000-0003-4093-779X>

Power system planning is responsible for the generation, transmission and distribution of electricity. Thus, an accurate forecast of electricity consumption is essential as it serves as the basis for energy management and operational decisions. This would be a big step forward for energy producers. In addition, improved energy data processing opens up new opportunities for data collection, exploration and more accurate forecasting. As a result, researchers around the world are trying to improve energy demand forecasts.

Therefore, energy companies need to explore models in order to better predict and plan energy use. One approach to solving this problem is the assessment of energy consumption at the consumer level. The energy consumption forecasting concern is a time series regression concern. It consists of predicting energy consumption for the next few days, given the customer's end story. Machine learning methods have shown promising results in a variety of tasks including time series and regression concerns. Some of these promising results are related to deep neural networks. Although deep model architectures have been explored in other areas, they have not been used to solve the power consumption prediction concern.

In this paper, we propose a new, efficient system for predicting monthly energy consumption using deep learning methods. The authors analyzed two machine learning models. Several architectures of neural network models have been developed. Model studies were carried out on a dataset that included historical data for 10 years. The results showed that the resulting architecture of the hybrid model can predict hourly energy consumption with a relative error of 5%.

The proposed solution could act on energy producers/distributors to help smart meters make better decisions to reduce overall energy consumption by limiting energy production.

Keywords: machine learning, neural networks, XGBoost, LSTM, RNN, CNN, energy forecasting, time series, energy

REFERENCES

1. Kitov V. V., Mishustina M.V., Ustyuzhanin A.O. Time series prediction survey of statistical, machine learning and deep learning methods: historical aspects. *Voprosy Istorii* [Issues of history], 2022, no. 4-2, pp. 201-218. (In Russian). doi: 10.31166/VoprosyIstorii202204Statyi40
2. Berdonosov V.D., Vasilev G.V., Zhivotova A.A. Analysis and development potential of predictive models for energy flows of autonomous hybrid energy systems// *Journal of physics: conference series*. 2021, vol. 2096, 012024. doi: 10.1088/1742-6596/2096/1/012024
3. Yesenkov A.S., Zakharova E.M., Kovaleva M.D., Konstantinov D.E., Makarov I.S., Pankovets E.A. Research and application of architectures of deep neural networks for classification on multidimensional time series. *Izvestiya rossiyskoy akademii nauk. Teoriya i sistemy upravleniya* [Proceedings of the Russian Academy of Sciences. Theory and control systems], 2022, no. 4, pp. 133-142. (In Russian). doi: 10.31857/s0002338822040072
4. Vasiliev G.V., Berdonosov V.D. Development and comparison of models for predicting electricity consumption using recurrent neural networks with long short-term memory. *Nauka, innovatsii i tekhnologii: Materialy Mezhdunarodnoy naucho-prakticheskoy konferentsii*. [Proceedings of the International Scientific and Practical Conference "Science, innovations and technologies: from ideas to implementation"]. Komsomolsk-on-Amur, 2022, pp. 203-206. (In Russian)
5. Vasiliev G.V., Berdonosov V.D. Analysis of energy flow models of hybrid energy systems. *Aktualnye problemy informatsionno-telekommunikatsionnykh tekhnologiy i matematicheskogo modelirovaniya v sovremennoy nauke i promyshlennosti: Materialy I mezhdunarodnoy nauchno-prakticheskoy konferentsii molodykh uchenykh* [Proceedings of the 1st International Scientific and Practical Conference of Young Scientists "Actual problems of information and telecommunication technologies and mathematical modeling in modern science and industry"]. Komsomolsk-on-Amur, 2022, pp. 191-194. DOI: 10.17084/978-5-7765-1488-3-2021-191. (In Russian)
6. Kandasamy P., Chandrasekaran K., Natarajan R., Selvaraj J. Deep CNN-LSTM-based dstatcom for power quality enhancement in microgrid. *Journal of circuits, systems, and computers*. 2022, vol. 31, no. 7, p. 2250130. doi: 10.1142/S0218126622501304
7. Dong X., Zong X., Wang J., Li P. Enterprise economic forecasting method based on ARIMA-LSTM model. Lecture notes

- of the institute for computer sciences, social-informatics and telecommunications engineering. 2022, vol. 429 LNICST, pp. 36-57. doi: 10.1007/978-3-030-99188-3_4
8. Ulloa N.I., Chiang S.H., Yun S.H., Furuta R. Sentinel-1 spatiotemporal simulation using convolutional LSTM for flood mapping. *Remote sensing*. 2022, vol. 14, no. 2, pp. 246. doi: 10.3390/rs14020246
 9. Rahman Z.U., Ullah S.I., Salam A., Rahman T., Khan I., Niazi B. Automated detection of rehabilitation exercise by stroke patients using 3-layer CNN-LSTM model. *Journal of Healthcare Engineering*. 2022, vol. 2022, pp. 1563707. doi: 10.1155/2022/1563707
 10. Safaraliev M.H., Matrenin P.V., Dmitriev S.A., Akhieev J.S., Kokin S.E. Adaptive ensemble models for medium-term forecasting of electricity generation by hydroelectric power plants in isolated energy systems, taking into account changes in temperature. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical systems and complexes]. 2022, no. 1(54), pp. 38-45. (In Russian). [https://doi.org/10.18503/2311-8318-2022-1\(54\)-38-45](https://doi.org/10.18503/2311-8318-2022-1(54)-38-45)
 11. Zhao B., Li X., Lu X. CAM-RNN: Co-attention model based RNN for video captioning. *IEEE Trans. Image Process.* 2019, vol. 28, no. 11, pp. 5552-5565. doi: 10.1109/TIP.2019.2916757
 12. Hong X., Lin R., Yang C., Zeng N., Cai C., Gou J., Yang J. Predicting Alzheimer's disease using LSTM. *IEEE Access*. 2019, vol. 7, pp. 80893-80901. doi: 10.1109/ACCESS.2019.2919385
 13. Alekseev A.O., Antonov V.I. Confirmation of the Electrical Network Configuration using the LSTM Neural Network. *Informatsionnye tekhnologii v elektrotekhnike i elektroenergetike: Materialy XIII Vserossiyskoy nauchno-tekhnologicheskoy konferentsii* [Proceedings of the 13th All-Russian Scientific and Technical Conference "Information technologies in electrical engineering and electric power industry"]. Cheboksary, 2022, pp. 340-344. (In Russian)
 14. Hasoon S.O., Al-Hashimi M.M. Hybrid deep neural network and long short term memory network for predicting of sun-spot time series. *International journal of mathematics and computer science*. 2022, vol. 17, no. 3, pp. 955-967.
 15. Meizer M.V., Severyanova E.D. An example of time series forecasting using a recurrent neural network LSTM. *Factor obespecheniya kachestva issledovaniy: Professionalnye kommunikatsii v nauchnoy srede - Materialy XI Vserossiyskoy nauchno-prakticheskoy konferentsii* [Proceedings of the 11th All-Russian Scientific and Practical Conference "Professional communications in the scientific environment - a factor in ensuring the quality of research"]. St. Petersburg, 2022, pp. 211-214. (In Russian)
 16. Timofeev A.G., Lebedinskaya O.G. Model of application of convolutional neural network (CNN) in combination with long-term memory (LSTM) for forecasting oil prices under uncertainty. *Transportnoe delo Rossii* [Transport business of Russia], 2022, no. 2, pp. 54-59. (In Russian). doi: 10.52375/20728689_2022_2_54
 17. Istamkulov H.S. Analysis of the use and application of LSTM architecture. *Sovremennaya nauka: aktualnye problem teorii i praktiki. Seriya: estestvennye i tekhnicheskienauki*. [Modern Science: Actual Problems of Theory and Practice. series: natural and technical sciences], 2022, no. 6, pp. 77-80. (In Russian). doi: 10.37882/2223-2966.2022.06.16
 18. Tuerxun W., Guo L., Xu C., Guo H., Gao Y., Zeng N. A wind power forecasting model using LSTM optimized by the modified bald eagle search algorithm. *Energies*. 2022, vol. 15, no. 6, p. 2031. doi: 10.3390/en15062031
 19. Zhao R., Lam K., Lun D.P.K. Enhancement of a CNN-based denoiser based on spatial and spectral. *IEEE international conference on image processing (ICIP)*. IEEE, 2019, pp. 1124-1128. doi: 10.1109/ICIP.2019.8804295
 20. Bakhmetenko O.A., Eliseeva A.A. Development of an algorithm for managing a microgrid with renewable energy sources taking into account short-term forecasts for the generation and consumption of electrical energy. *Elektroenergetika glazami molodezhi: Materialy XI Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii* [Proceedings of the 11th International Scientific and Technical Conference "Power industry through the eyes of youth"]. Stavropol, North Caucasian Federal University Publ., 2020, pp. 149-150. (In Russian)
 21. Stern Yu.I., Kozhevnikov Ya.S., Medvedev V.A., Mironov R.E., Karavaev I.S. Methods for determining the individual consumption of thermal energy, implemented on the basis of an intelligent system for monitoring energy resources. *Izmeritel'naya tekhnika* [Measuring equipment], 2022, no. 2, pp. 46-50. (In Russian)
 22. Slyusareva V.A., Budantsev A.V. Research and forecasting of time series. *Aktualnye issledovaniya* [Actual research], 2022, no. 21 (100), pp. 33-37. (In Russian)
 23. Chen Y., Long C., Cong G., Li C. Context-aware deep model for joint mobility and time prediction. *WSDM 2020 Proceedings of the 13th International Conference on Web Search and Data Mining (WSDM)*. Association for Computing Machinery, 2020, pp. 106-114. doi: 10.1145/3336191.3371837
 24. Meizer M.V., Severyanova E.D., Mokshin V.V. An example of time series forecasting using a recurrent neural network LSTM. *Molodoy uchenyi* [Young scientist], 2022, no. 9(404), pp. 13-15. (In Russian)
 25. Shishkov E.M., Pronichev A.V., Savelyev A.A. Forecasting time series using machine learning methods on the example of the power output schedule of a power plant. *Mezhdunarodnyi nauchno-issledovatel'skiy zhurnal* [International Research Journal], 2022, no. 2-1(116), pp. 56-60. (In Russian). doi: 10.23670/IRJ.2022.116.2.009
 26. Emaletdinova L.Yu., Kabirova A.N., Vildanov N.R. Neural network modeling of the problem of predicting the values of the time series. *Vestnik tekhnologicheskogo universiteta* [Bulletin of the Technological University], 2022, vol. 25, no. 10, pp. 101-106. (In Russian). doi: 10.55421/1998-7072_2022_25_10_101
 27. Devrishev N.E., He Yu., Petrosyan O.L. Detection of anomalies in time series using forecasting methods. *Protsessy upravleniya i ustoychivost* [Management processes and stability], 2022, vol. 9, no. 1, pp. 202-209. (In Russian)
 28. Evstigneev I.P. Time Series Forecasting. *Sistemnyi administrator* [System Administrator], 2022, no. 7-8(236-237), pp. 138-139. (In Russian)
 29. Timofeev G.A., Berdonosov V.D. Use of actual tools for data collection and analysis. *Nauka, innovatsii i tekhnologii: ot idey k vnedreniyu: Materialy Mezhdunarodnoy nauchno-prakticheskoy konferentsii* [Proceedings of the International Scientific and Practical Conference "Science, innovations and technologies: from ideas to implementation"]. Komso-molsk-na-Amur, 2022, pp. 257-258. (In Russian)

Васильев Г.В., Бердоносков В.Д. Методика по эффективному применению гибридных моделей нейронных сетей для прогнозирования энергопотребления // Электротехнические системы и комплексы. 2022. № 4(57). С. 88-95. [https://doi.org/10.18503/2311-8318-2022-4\(57\)-88-95](https://doi.org/10.18503/2311-8318-2022-4(57)-88-95)

Vasilev G.V., Berdonosov V.D. Methodology for Effective Application of Hybrid Models of Neural Networks for Energy Consumption Prediction. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical Systems and Complexes], 2022, no. 4(57), pp. 88-95. (In Russian). [https://doi.org/10.18503/2311-8318-2022-4\(57\)-88-95](https://doi.org/10.18503/2311-8318-2022-4(57)-88-95)