

Нейросетевой подход к прогнозированию объемов и цен оптового рынка электроэнергии с использованием разночастотных данных

Научный руководитель – Каукин Андрей Сергеевич

Косарев Владимир Сергеевич

Выпускник (магистр)

Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации, Экономический факультет, Москва, Россия

E-mail: kosarevvladimirserg@gmail.com

Эффективность управления и планирования в критически важном для экономики электроэнергетическом секторе зависит от точного прогнозирования спроса на электроэнергию. Для генераторов оптового рынка электроэнергии особенно остро стоит проблема краткосрочного прогнозирования, поскольку процесс запуска и остановки генерирующего оборудования является трудоемким и дорогостоящим процессом. Мы хотим представить разработанную гибридную модель машинного обучения для задачи условного прогнозирования спроса на электроэнергию на рынке на сутки вперед, позволяющую использовать разночастотные данные среди объясняющих переменных.

Во многих работах [1,2,3] по прогнозированию спроса на электроэнергию используются модели с одинаковой частотой наблюдений объясняющих переменных. Однако показатели энергетического рынка, в том числе цены и объемы произведенной электроэнергии, могут иметь высокую частоту измерения - часы и минуты. И, соответственно, прогноз, имеющий практическую ценность для генераторов, должен быть построен с таким же уровнем детализации. При этом большая часть причинных экономических факторов имеет меньшую частоту измерения - месячную (индексы промышленного производства) или квартальную (валовый региональный продукт). При этом включение таких факторов в модель позволяет лучше прогнозировать трендовую компоненту спроса. Таким образом, возникает проблема совмещения данных разной частотности.

В практике обработки временных рядов, как правило, данные с более высокой частотой агрегируются до самой низкой частоты путем усреднения, суммирования или взятия репрезентативного значения (например, первый месяц года), либо, наоборот, данные с более низкой частотой интерполируются до самой высокой частоты. Однако, при агрегации теряется информация о структуре временного ряда, что приводит к ухудшению качества модели. При использовании обычных методов интерполяции, как правило, не учитывается вся доступная информация о выборке. Существующие модели, совмещающие разночастотные данные при прогнозировании, такие как MIDAS[4] или VARMA[5], работают удовлетворительно с задачами прогнозирования низкочастотной переменной, обусловленной высокочастотными данными. И хотя существует модификация MIDAS модели, позволяющая делать обратное, преобразование данных внутри такой модели происходит линейно и требует использования экзогенных весовых коэффициентов, что потенциально также приводит к потере информации или зашумлению исходных данных.

Предлагаемая модель представляет собой комбинацию сверточной (CNN) и рекуррентной сети (LSTM) с механизмом внимания. Возможность использования разночастотных данных в такой сети обусловлена специальной конструкцией сверточного блока. Идея состоит в том, что данные с разной частотой измерения подаются в сеть в виде двух отдельных матриц. К каждой матрице затем применяются операции, сводящие данные к одной размерности при помощи аффинных преобразований с обучаемыми параметрами. Первая матрица имеет размерность $n_1 * m_1$, где n_1 - это гиперпараметр, отвечающий за

продолжительность временного окна высокочастотных данных, а m_1 - число факторов. Протяженность данного окна определяет протяженность рецептивного поля, а количество факторов - его ширина для применяемого в последующем сверточного слоя, что и есть аффинные преобразования для матрицы с высокочастотными данными. В результате размерность высокочастотных данных внутри сети сокращается. Масштаб сокращения размерности определяется внутренними параметрами сверточного слоя. Вторая матрица имеет размерность $n_2 * m_2$, где n_2 - это продолжительность временного окна для низкочастотных данных, а m_2 - число факторов. С матрицей низкочастотных данных совершается обратная операция - увеличение размерности от n_2 до n_1 по оси времени.

Приведенные к одной размерности месячные и часовые данные используются совместно для выделения значимых паттернов при прогнозировании непосредственно рекуррентной нейронной сетью. В процессе обучения в данном блоке главным образом определяются временные закономерности, а также строится отображение входного вектора в отдельные пространства с уникальными паттернами. После рекуррентного блока полученный вектор передается в сеть внимания. Сеть внимания определяет какой из выделенных паттернов окажет большее влияние на построение прогноза в определенный момент времени. Затем данные попадают в последний выходной слой нейросети, который представляет сумматор с линейной функцией активации. Выход нейронной сети - это объем спроса на электроэнергию в определенный час в некоторой ценовой зоне. Для долгосрочного прогноза выход может быть расширен до необходимого количества прогнозных значений. На прилагаемом рисунке приведена архитектура описанной нейронной сети.

По результатам серии экспериментов точность прогноза предложенной модели, измеряемая как средняя ошибка на тестовых выборках валидационных множеств, превосходит ряд моделей бенчмарков, среди которых классические архитектуры нейронных сетей и линейная авторегрессионная модель.

Источники и литература

- 1) Kim T. Y., Cho S. B. Predicting residential energy consumption using CNN-LSTM neural networks //Energy. – 2019. – Т. 182. – С. 72-81.
- 2) Kuo P. H., Huang C. J. A high precision artificial neural networks model for short-term energy load forecasting //Energies. – 2018. – Т. 11. – №. 1. – С. 213.
- 3) Chen Y. et al. Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings //Applied Energy. – 2017. – Т. 195. – С. 659-670.
- 4) Ghysels E., Santa-Clara P., Valkanov R. The MIDAS touch: Mixed data sampling regression models. – 2004.
- 5) Zdrozny P. Gaussian likelihood of continuous-time ARMAX models when data are stocks and flows at different frequencies //Econometric Theory. – 1988. – Т. 4. – №. 1. – С. 108-124.

Иллюстрации

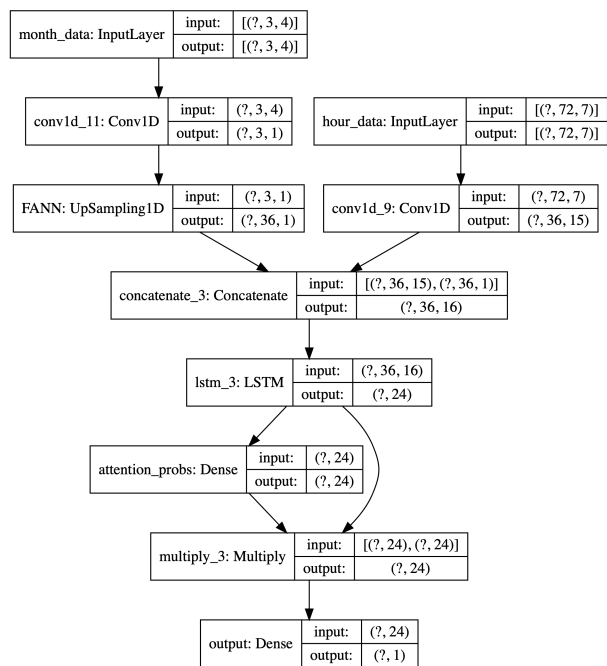


Рис. : Архитектура предложенной модели