

УДК 621

ОЦЕНКА ВЛИЯНИЯ ГИПЕРПАРАМЕТРОВ НЕЙРОСЕТИ НА ТОЧНОСТЬ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ

Шмытикова Ксения Валерьевна группа М-13 2 курс

Руководитель: преподаватель кафедры ЭиМ Полуянович Н.К.

Колледж ППО ИРТСУ Южный федеральный университет ЮФУ

Г. Таганрог Россия.

Данная работа посвящена проблеме повышения точности краткосрочного прогнозирования потребления электроэнергии с помощью инструментов глубокого машинного обучения.

Введение. На данный момент, ситуация в сфере электроснабжения является не удовлетворительным. Значительный физический износ оборудования, высокий показатель удельных расходов топлива и потери в сетях.

Проблема прогнозирования электропотребления заключается в том, что необходимо учесть огромное количество факторов, которые имеют влияние на изменение энергопотребления. Новые подходы к прогнозированию электрической нагрузки работают на данный момент на нейросетевом моделировании, позволяющем минимизировать вмешательство в работу системы управления на этапе сбора данных об исследуемом объекте.

Цель: Целью данной работы является обеспечение баланса между выработанной и потребленной электроэнергией.

Постановка задачи: Это в первую очередь разработка оптимальной структуры системы прогнозирования для потребителей с различным характером электропотребления, другими словами не повторяющимся значением за рассматриваемые периоды времени.

Алгоритмы обучения глубоких нейронных сетей, предназначенных для краткосрочного прогнозирования электропотребления, включают оптимизацию в различных контекстах.

Представлен список основных параметров архитектур, для нейронных сетей:

- количество скрытых слоев сети;
- количество нейронов в каждом скрытом слое;
- функция активации нейронов скрытых и выходного слоев;
- оптимизаторы функции потерь.

Влияние размера пакета (BatchSize) и влияние количества слоев.

Скорость обучения нейросети зависит от различных факторов, которые влияют на эффективность процесса обучения и время, необходимое для достижения конвергенции модели.

Для случая аддитивных входных параметров есть исследование влияние количества слоев на скорость обучения нейронной сети (НС), оно приведено на рис. 1.

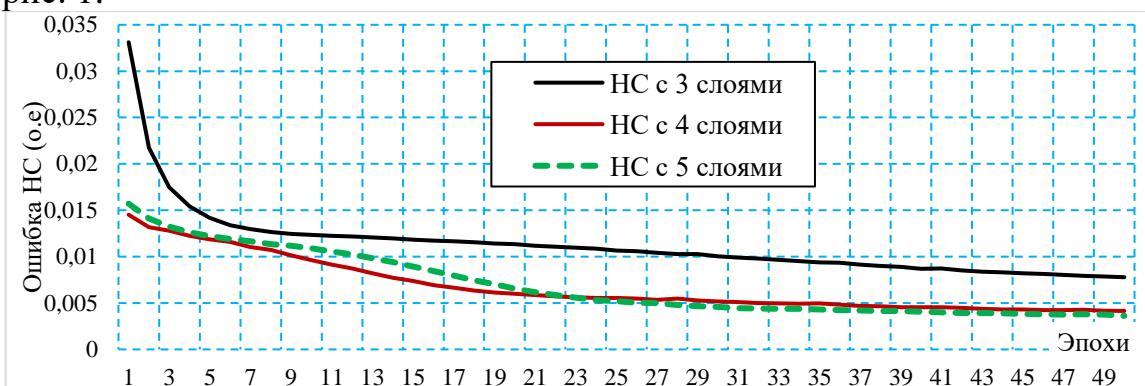


Рис. 1. Влияние количества слоев на скорость обучения НС

Наблюдается понижение ошибки нейронной сети прогнозирования с разным количеством слоев.

Результаты погрешностей НС-модели с разным количеством слоев, в случае дополнительного характера электропотребления, представлены в таблице 1.

Таблица 1.

Влияние количества слоев на точность предсказаний НС

Количество слоев в НС	Количество эпох	Среднее отклонение предсказаний НС, %
3	47	17,10
4	24	13,72
5	24	0,79

Анализируя рис. 1 и таблицу 1 видим, что с большим количеством слоев нейронная система обучается быстрее и ее предсказания точнее.

Влияние оптимизатора.

Оптимизатор – это метод достижения лучших результатов и помощь в ускорении обучения.

Если говорить другими словами, это алгоритм, используемый для незначительного изменения параметров, таких как веса и скорость обучения, чтобы модель работала правильно и быстро.

Для обучения прогностической НС-модели, наиболее распространены следующие оптимизаторы:

1. **Стochastic gradient descent (SGD)** – это мини-пакетный градиентный спуск, который стремится сбалансировать устойчивость стохастического градиентного спуска и эффективность пакетного градиентного спуска.

Это наиболее распространенная реализация градиентного спуска, используемая в области глубокого обучения. Он имеет ряд преимуществ перед стандартным градиентным спуском, таких как более быстрая конвергенция и меньшие требования к памяти, особенно для больших

наборов данных. Он также может выходить за пределы локальных минимумов, что является очень эффективным.

2. **Momentum**. - это метод оптимизации, используемый в машинном обучении и глубоком обучении для ускорения нейронных сетей. Он основан на идеи добавления части предыдущего обновления к текущему обновлению весов в процессе оптимизации.
3. **Среднеквадратичное распространение корня (RMSprop)** – это алгоритм оптимизации, используемый в машинном обучении и глубоком обучении для оптимизации обучения нейронных сетей. В целом это мощный алгоритм оптимизации, который может помочь ускорить обучение глубоких нейронных сетей и повысить их производительность.
4. **Адаптивная оценка момента (Adam)** – один из самых эффективных алгоритмов оптимизации в обучении нейронных сетей. Он сочетает в себе идеи предыдущего и оптимизатора импульса. Вместо того чтобы адаптировать скорость обучения параметров на основе среднего первого момента (среднего значения), как и в предыдущем, Adam также использует среднее значение вторых моментов градиентов.

Анализируя скорость обучения различных оптимизаторов наилучшие результаты демонстрируют оптимизаторы “Adam” и “RMSprop”. Они могут послужить хорошими помощниками для быстрого и более глубокого обучения нейронных сетей.

Влияние функции активации.

От выбора функции активации зависит то, насколько быстро будет обучаться нейронная сеть и насколько точными будут ее прогнозы. Так же при выборе функции активации важно нормировать входные данные таким образом, чтобы область ее определения совпадала с областью определения данных.

Если входные данные будут иметь отрицательные значения, то функция активации должна иметь отрицательные значения в своей области определения, иначе нейронная сеть будет терять часть информации.

Методы регуляризации.

Регуляризация нейронных сетей – это мощный инструмент, который помогает контролировать переобучение и повышать обобщающие способности моделей. Путем применения различных методов регуляризации и их оптимального настройки, можно достичь более стабильных и надежных результатов в задачах машинного обучения.

Ее преимущество заключается в том, что она позволяет уменьшить размер весов модели и сделать их более равномерными, тем самым повышая устойчивость модели к малым изменениям данных.

При выборе метода регуляризации важно учитывать, что слишком сильная регуляризация может привести к ошибке, тогда как недостаточная может привести к переобучению.

Виды методов регуляризации:

1. **L1-регуляризация.** Часто называют регрессией лассо или Манхэттенской. Суть данного метода заключается в добавлении к функции потерь суммы абсолютных значений весовых коэффициентов.

$$L_{L1}(Y, Y', W) = L(Y, Y') + \lambda \sum_{i=1}^n |w_i|,$$

где:

$L_{L1}(Y, Y', W)$ – функция потерь с L1-регуляризацией;

$L(Y, Y')$ – одна из рассмотренных ранее функций потерь;

λ – коэффициент регуляризации (штраф);

w_i – i-ый весовой коэффициент.

2. **L2-регуляризация.** L2, или гребневая регуляризация, как и предыдущая вводит в функцию потерь остаток за большие весовые коэффициенты. Но при этом используется L2-норма — сумма квадратов весовых коэффициентов.

$$L_{L2}(Y, Y', W) = L(Y, Y') + \lambda \sum_{i=1}^n w_i^2$$

L2-регуляризация вводит штраф за большие веса, тем самым усиливает влияние важных признаков и снижает, но не исключает, влияние случайного шума на конечный результат.

3. **Регуляризация нейросетей с помощью dropout.**

Dropout – это метод, который случайным образом отключает некоторые нейроны в процессе обучения, чтобы уменьшить переобучение. Dropout может быть вычислен параллельно и не требовать дополнительные вычислительные ресурсы.

Преимуществом использования dropout является:

- уменьшение переобучения;
- улучшение обобщающей способности;
- эффективность.

Регуляризация играет важную роль в улучшении обобщающей способности нейронных сетей. Она помогает избежать переобучения и сделать модель более устойчивой к новым данным.

Использование различных методов регуляризации позволяет нейронным сетям достичь лучших результатов на практике, улучшая их способность к обобщению и увеличивая точность предсказаний.

Экспериментальные исследования

Многофакторное моделирование электропотребления. Для обучения и тестирования алгоритмов необходимо произвести выборку и описание входных параметров.

Для этого необходимы следующие значимые факторы:

- Социально-экономические: (Время, (t – час, сутки, неделя, месяц); Дата (D – день, M – месяц, Y – год); Статус дня (S; 1 – рабочий, 0 – выходной))
- Метеорологические: (Температура среды (T); Наличие осадков (R; 1 – осадки есть, 0 – осадков нет); Скорость ветра (W))

Настройка НС.

Алгоритмы обучения глубоких нейронных сетей, предназначенных для краткосрочного прогнозирования электропотребления, включают оптимизацию в различных контекстах.

Основная задача оптимизации в машинном обучении заключается в подборе параметров нейронной сети.

В список основных параметров архитектур для нейронных сетей входят:

- количество скрытых слоев сети;
- количество нейронов в каждом скрытом слое;
- функция активации нейронов скрытых и выходного слоев.

Тестирование нейросети.

Для исследования нейросетей, важны были гиперпараметры, которые давали бы точную характеристику.

Рассматривались такие гиперпараметры как:

- тип распространения ошибки
- скорость обучения
- обучающая функция.

Погрешность прогнозирования с различными вариантами гиперпараметров нейронной сети, приведены в таблице 5.

Таблица 5

Оценка влияния гиперпараметров НС на погрешность прогноза

Параметр	Значение	Погрешность прогнозирования %	
		Средняя по часам	Средняя за период
Обучающая функция	trainbr	31,79	15,79
	trainlm	259,79	244,38
Тип ошибки	MSE	30,28	6,14
	SSE	26,31	14,38
Скорость обучения, о.е.	0,00001	25,19	15,95
	0,0001	30,28	6,14
	0,01	31,12	20,91

Рассчитаны погрешности прогнозирования при различных комбинациях параметров НС-модели, они приведены в таблице 6.

Таблица 6

Результаты прогнозирования электропотребления

Способ измерения погрешности	Номер комбинации параметров НС-модели	Погрешность прогнозирования %
Средний по часам	1	30.76
	2	26.80
	3	26.31
Средний за период	1	12.81
	2	15.59
	3	14.38

Проведено и исследование для двух различных типов потребителей, аддитивного, и имеющего циклический характер. Прогнозирование потребителя электроэнергии с аддитивным характером, для трех вариантов настройки НС-модели приведено на рисунке 6.

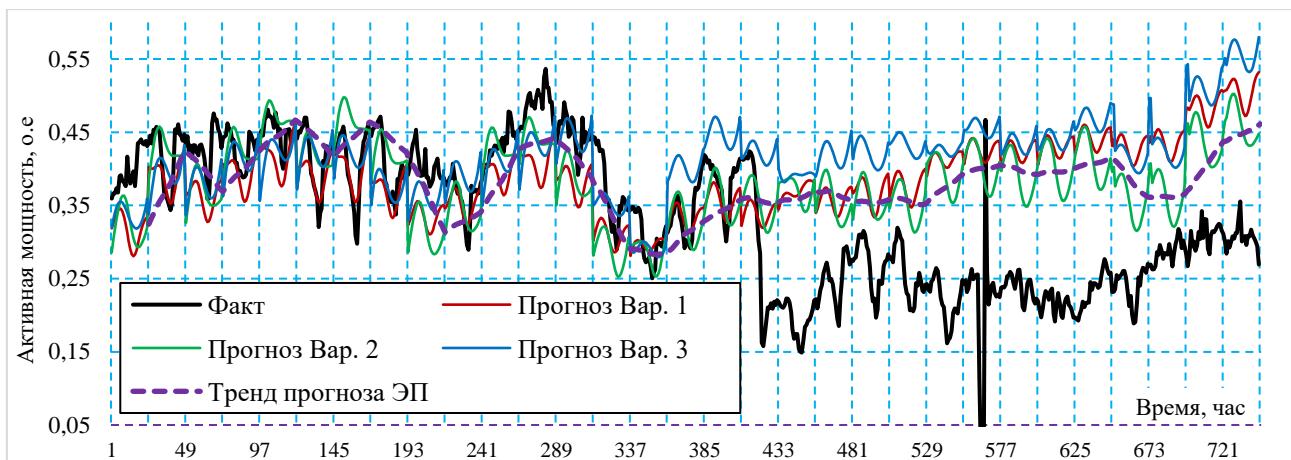


Рис. 1. График сравнения фактических и прогнозных значений (Вариант 1-3)

Анализ полученных зависимостей (рис. 1) прогнозирования электропотребления показал, что в момент резкого скачка погрешность используемой НС-модели существенно увеличилась, что говорит о некорректной работе данной НС-модели. Как уже было сказано, НС-модель небольшого размера не обеспечивает требуемой точности. Использование метода при исследовании должно уменьшить погрешность прогнозирования на подобных участках кривой электропотребления, чтобы достичь нужного результата.

Заключение. Проведено исследование влияния различных параметров и структуры нейросети на точность прогнозирования энергопотребления с целью нахождения оптимальных ее настроек (т.е. наименьшая погрешность). Определены наиболее соответствующие гиперпараметры НС-модели для прогнозирования потребителей аддитивного и циклического типа.

При прогнозировании электропотребления с циклическим характером оптимальные параметры НС:

- кол-во скрытых слоев ;

- количество нейронов на слой – 10-10;
- функция активации Tansig-Tansig, а в выходном слое Purelin);
- тип распространения ошибки (MSE);
- скорость обучения (0,0001);
- обучающая функция (TrainBR - Байесовская регуляризация).

В случае аддитивного потребителя электроэнергии подобраны оптимальные параметры:

- кол-во скрытых слоев (1);
- количество нейронов на слой – 10;
- функция активации Tansig, а в выходном слое Purelin;
- тип распространения ошибки (MSE);
- скорость обучения (0,001); обучающая функция (TrainBR - Байесовская регуляризация), предпочтительно использование метода СО.

Выявлено, что для обеспечения наименьшей погрешности прогнозирования, необходима индивидуальная настройка параметров нейросети для каждого потребителя в отдельности с учётом его характера энергопотребления.

Список литературы:

Н.К. Полуянович, М.Н. Дубяго. / Алгоритм обучения искусственной нейронной сети факторного прогнозирования ресурса изоляционных материалов силовых кабельных линий. // ж. Известия ЮФУ. Технические науки. “Izvestiya SFedU. Engineering sciences” №2 2021. С.59-73.

Н.К. Полуянович, М.Н. Дубяго. / Оценка действующих факторов и прогнозирование электропотребления в региональной энергосистеме с учетом режима ее эксплуатации. // ж. Известия ЮФУ. Технические науки. “Izvestiya SFedU. Engineering sciences” №2(226) 2022. С.180-194C.31-46.

Дубяго М.Н., Полуянович Н.К. / Совершенствование методов диагностики и прогнозирования электроизоляционных материалов систем энергоснабжения. Монография / М. Н. Дубяго, Н. К. Полуянович; Южный федеральный университет. – Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2019. – 192 с.