

УДК 004.891.2

**ОЦЕНКА ТОЧНОСТИ РОБАСТНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ
ДЛЯ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ**

О.В. Качелаев, аспирант ИРТСиУ, ЮФУ

К.В. Шмытикова, группа М-13, Колледж ППО

Руководитель: доцент кафедры ЭиМ Полуянович Н.К.

ИРТСУ ЮФУ, г. Таганрог, Россия

Данная работа посвящена проблеме повышения точности краткосрочного прогнозирования потребления электроэнергии с помощью инструментов глубокого машинного обучения. Рассмотрены основные параметры архитектуры нейронных сетей: – количество скрытых слоев сети; – количество нейронов в каждом скрытом слое; – функция активации нейронов скрытых и выходного слоев; – оптимизаторы; – функции потерь. Проведено исследование их влияния на точность прогнозирования электропотребления. Определены оптимальные параметры архитектуры нейросети для задач прогнозирования электропотребления. Рассмотрено применение робастной модификации алгоритма обратного распространения ошибки для обучения нейросети.

– использование так называемых робастных или устойчивых методов, которые позволят не исключать нетипичные наблюдения, а снизить их негативное влияние на работу модели.

Введение. Развитие электроэнергетических систем осуществляется в соответствии с реализацией концепции Smart Grid, определяемой в России как интеллектуальная энергетическая система (ИЭС) [1]. У крупных промышленных предприятий в современных условиях потребления электроэнергии возникает задача составления заявки в энергоснабжающую организацию на объем электроэнергии, необходимый в определенный период времени. Своевременное получение информации о предстоящей нагрузке позволяет выбрать оптимальный режим работы системы.

Проблема прогнозирования электропотребления заключается в том, что необходимо учесть огромное количество факторов [2], которые имеют влияние на изменение энергопотребления. Новые подходы к прогнозированию электрической нагрузки основаны на нейросетевом моделировании, позволяющем обрабатывать большие объемы данных за малый промежуток времени. Однако классические методы решения задач машинного обучения позволяют добиться высокой точности работы только в тех случаях, когда анализируемые данные являются достаточно «хорошими».

Задача работы заключается в разработке оптимальной структуры НС-модели прогнозирования для потребителей с различным характером электропотребления, другими словами не повторяющимся значением за рассматриваемые периоды времени. Каждый из гиперпараметров влияет на способность сети обучаться и обобщать информацию, что напрямую сказывается на её

производительности. Правильный выбор параметров позволяет избежать переобучения и улучшить качество прогноза.

Влияние размера пакета (BatchSize). Скорость обучения нейросети [3] зависит от различных факторов, которые влияют на эффективность процесса обучения и время, необходимое для достижения конвергенции модели. На рис. 1 приведена зависимость эффективности обучения (отклонения прогнозирования НС) от задаваемого при обучении размера пакета (Batch size).



Рис. 1 – Отклонение прогнозирования НС, от задаваемого размера пакета

Анализ рис. 1 показал, что чем больше пакет входных данных, тем эффективнее обучается НС. Однако, чем больше пакет входных данных, тем больше требуется оперативной памяти для процесса обучения. Поэтому все последующие тесты будут проводиться с размером пакета входных данных равным 250, что является оптимальным размером для 8Гб оперативной памяти.

Влияние количества слоев. Для случая аддитивных входных параметров исследовано влияние количества скрытых слоев на продолжительность обучения НС-модели. Зависимость ошибки от количества эпох приведена на рис. 2.




Рис. 2. Влияние количества слоев на скорость обучения НС

Наблюдается понижение ошибки нейронной сети прогнозирования с увеличением количества слоев. Результаты расчета 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

Анализ рис. 2 и табл. 1 показал, 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. Иначе – 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: Стохастический градиентный спуск (SGD); Momentum; Среднеквадратичное распространение корня (RMSprop); Адаптивная оценка момента (Adam).

Сравнение скорости падения ошибки НС, в зависимости от оптимизатора применяемого в процессе обучения приведено на рис. 3




Рис. 3. Сравнение скорости обучения с различными оптимизаторами

Анализ скорости обучения различных оптимизаторов наилучшие результаты демонстрируют оптимизаторы “Adam” и “RMSprop”.

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.

К наиболее распространенным функциям активации относятся: логистическая (logsig); гиперболический тангенс (tansig); Полулинейная (ReLU); линейная

(linear). Для выбора оптимальной функции активации нейронной сети проведено сравнение скорости падения ошибки НС, в зависимости от функции активации, рис. 4.




Рис. 4. Сравнение ошибки с разными функциями активации нейронов

Анализ рис. 4 показал, что функция активации “ReLU” показывает наилучший результат среди остальных функций активации. Так же хорошо себя показали функции активации “Leaky ReLU” и “tanh” (tansig).

Робастное обучение НС. Искусственные нейронные сети (ИНС) являются мощным инструментом анализа данных, в то время как генетические алгоритмы (ГА) известны как робастные методы оптимизации, благодаря способностям к адаптации. Пусть параметры линейной регрессии оцениваются по пяти наблюдениям, которым на рис. 5 соответствуют точки серого цвета. Проходящая через точку А прямая соответствует истинной зависимости. Таким образом, наличие даже одного выброса в исследуемых данных приводит к резкому увеличению суммы квадратов остатков, что плохо скажется при оценивании параметров с помощью МКТ. В связи с этим применяют альтернативный подход к решению данной проблемы — использование так называемых робастных или устойчивых методов [4]/




Рис. 5. Влияние выброса на оценивание параметров линейной регрессии

Робастный подход, является альтернативой классическим методам обучения НС. Он позволяет не исключать нетипичные наблюдения, а снизить их негативное влияние при обучении модели и, тем самым, добиться достаточно высокой точности работы модели при анализе зашумленных данных. При решении других задач машинного обучения, однако, такой подход до сих пор используется не очень часто. В данной работе рассматривались такие функции потерь как: Хьюбера; Коши (Лоренца); MSE (среднеквадратичная ошибка).

Робастная модификация НС. Исследовано влияние на погрешность прогнозирования ЭП применения робастных функций потерь вместо классической MSE. Проведен расчет ошибки прогнозирования при использовании различных функций потерь, таблица 2

Таблица 2. Ошибка прогнозирования при различных функциях потерь

Характер потребления электро- энергии Функция потерь		Погрешность прогнозирования, %		
		Циклический	Аддитивный	
			AP-103	AP-204
Месяц	MSE	5.75	5.58	10.08
	Хьюбер	5.46	2.48	4.97
	Коши	5.77	9.8	15.7

Анализ результатов проведенного исследования показал:

- Для потребителей ЭЭ с циклическим профилем лучше всего себя показывают функции потерь MSE и Хьюбера, снижение ошибки до 2%;
- Для потребителей с аддитивным профилем наибольшую эффективность показала робастная функция потерь Хьюбера. Снижение точности по сравнению с MSE – до 6-7%.

Как пример приведено экспериментальное исследование влияния различных параметров обучения НС-модели в среде MATLAB NNtool.

Некоторые варианты (комбинаций параметров НС) для потребителей с различным характером электропотребления, приведены в таблице 3.

Таблица 3. Комбинации параметров НС

Номер комбинации параметров	Количество слоев НС, j	Число нейронов в слое, n	Скорость обучения, Lr	Функция активации, Fa	Тип ошибки
Комбинации параметров НС-модели для потребителя МАКР					
1	1	10	0.01	[Tansig]	MSE
2	1	10	0.01	[Tansig]	SSE
3	1	10	0.0001	[Tansig]	MSE
Комбинации параметров НС-модели для потребителя ЮЗЭС					
1	2	10;10	0.01	[Tansig, Tansig]	MSE

2	1	25		[Tansig]	MSE
3	1	30		[Tansig]	MSE
Комбинации параметров НС-модели для потребителя МАКР со скользящим окном					
1	1	10	0.0001	[Tansig]	MSE
2	1	10	0.001	[Tansig]	MSE
3	1	10	0.00001	[Tansig]	MSE

Рассматривались такие параметры как: тип распространения ошибки; скорость обучения; обучающая функция. Расчет погрешности прогнозирования с различными вариантами гиперпараметров нейронной сети, приведен в таблице 4.

Таблица 4. 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	59,79	44,38
Тип ошибки	MSE	30,28	6,14
	SSE	26,31	14,38
Скорость обучения	0,00001	25,19	15,95
	0,0001	30,28	6,14
	0,01	31,12	20,91

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




Рис. 6. График сравнения фактических и прогнозных значений (Вариант 1-3)

Анализ полученных зависимостей (рис. 6) 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 типа.: – кол-во скрытых слоев (1); – количество нейронов на слой – 10; – функция активации Tansig, (выходной слое Purelin); – тип распространения ошибки (MSE); – скорость обучения (0,001); – обучающая функция (TrainBR - Байесовская регуляризация)

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

Список литературы:

1. 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.
2. Н.К. Полуянович, М.Н. Дубяго. / Оценка воздействующих 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.180-194С.31-46.
3. 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.
4. Сивак М.А Робастное обучение нейронных сетей с простой архитектурой для решения задач классификации: дисс. ... канд. наук: 05.13.17. – Новосибирск: НГТУ, 2022. – 111 с