

## ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ ПРЯМОГО РАСПРОСТРАНЕНИЯ ДЛЯ ОЦЕНКИ ПОТЕРЬ АКТИВНОЙ МОЩНОСТИ В РАСПРЕДЕЛИТЕЛЬНЫХ СЕТЯХ

6-10 кВ

Камилов Акмал Нормуродович

Магистрант.

Шахриева Лобар Нурматуллаевна

Магистрант.

<https://doi.org/10.5281/zenodo.18315586>

Как известно, расчеты установившихся режимов (УР) в распределительных сетях (РС) представляет собой определение параметров режима при известных схемных параметрах и данных узлов нагрузок или головного узла [1].

Определяемыми параметрами режима являются напряжения в узлах, токи, мощности и потери мощности на участках и сети в целом. При этом для выполнения расчётов используются итерационные методы, в частности двухэтапный метод, метод Ньютона и др.

Использование итерационных методов связано с большими математическими и вычислительными трудностями, а также они малоэффективны для оперативных расчетов, ввиду больших временных затрат.

Именно поэтому поиск наиболее быстрых методов является важной задачей.

Развитие методов вычислительной математики и информационных технологий позволяет по-новому ставить вопросы совершенствования оперативного управления режимами РС. В настоящее время перспективным представляется использование искусственных нейронных сетей (ИНС)[2,3].

Учитывая отмеченное в работе рассмотрена задача оценки потерь активной мощности в сети с применением ИНС прямого распространения.

Принцип действия ИНС основан на аппроксимации входных данных посредством уже имеющихся данных различных режимов работы РС. Так для оценки суммарных потерь мощности ИНС должны быть спроектированы и обучены при аппроксимации функции:

$$\Delta P_{sum} = F(U_{GU}, P_j, Q_j), \Delta Q_{sum} = F(U_{GU}, P_j, Q_j), \quad (1,2)$$

где  $\Delta P_{sum}$ ,  $\Delta Q_{sum}$  - суммарные потери мощности в сети;  $P_j$ ,  $Q_j$  - средние нагрузки в узлах;  $U_{GU}$  - напряжение головного узла.

С целью выполнения сравнительного анализа результатов расчёта УР распределительных сетей, рассмотрены ИНС прямого распространения с одним или более скрытыми слоями. В данных ИНС информация перемещается только в одном направлении от входных данных, через скрытые слои к выходу. Первый тип –многослойный перцептрон (fitnet), а второй тип ИНС каскадного типа(cascadeforwardnet), особенностью которой является наличие связи каждого слоя со всеми предыдущими.

Построение моделей предполагает выполнение следующих этапов:

- 1.Формирование статистических данных, и их разбивка на выборки.
- 2.Выбор архитектуры ИНС и ее обучение на обучающей выборке.
- 3.Оценка адекватности ИНС на тестовой выборке.
4. Формирование данных валидационной выборки.

5. Выбор лучшей модели ИНС по данным валидационной выборки.

В алгоритме шаги 2 и 3 выполняются для каждого типа ИНС.

Для выполнения необходимых расчётов выбраны ряд схем распределительных сетей напряжением 6-10 кВ. В качестве примера рассмотрим схему 10 узловой РС напряжением 10 кВ (Рис.1).

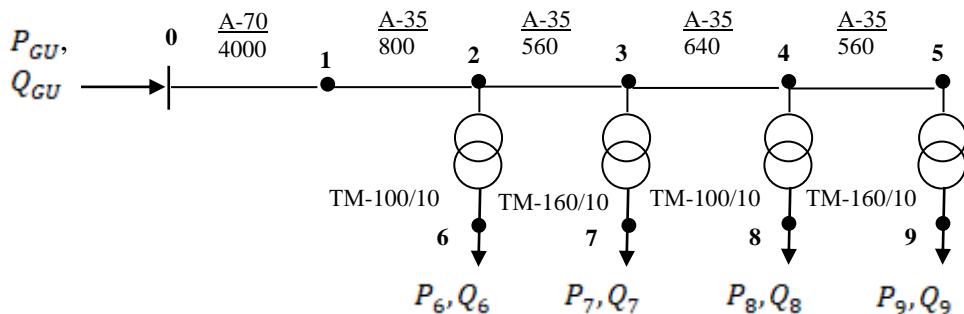


Рис.1. Оперативная схема распределительной сети 10 кВ

С целью формирования статистических данных, на основе представленной выше методики, было выполнено 1000 расчётов, при изменении следующих параметров: напряжение головного узла  $U_{GU} = 9.5 \div 10.5$  кВ; коэффициент загрузки трансформаторов  $k_z = 0.1 \div 0.8$ ; коэффициент мощности головного узла  $\cos\varphi = 0.7 \div 0.9$ ;

На основе введённых данных и результатов расчётов сформирована генеральная выборка состоящая из 1000 пар статистических данных “входы-выходы”. В данном случае входными данными являются напряжение головного узла, мощности узлов нагрузок ( $U_{GU}, P_6, Q_6, P_7, Q_7, P_8, Q_8, P_9, Q_9$ ), а выходными данными являются значения потерь мощности ( $\Delta P_{sum}, \Delta Q_{sum}$ ).

Полученная база данных разбивается на обучающую и контрольную выборки.

Обучающая выборка используется для подстройки весов и включает 70 % данных.

Тестовая включает 30 % данных которые не участвуют в процессе обучения и служат для проверки качества обучения каждой из ИНС.

Помимо указанной базы данных также формируется и валидационная выборка которая используется для выбора наилучшей модели и включает 100 пар данных «входы-выходы», при изменении следующих параметров:

$$U_0 = 9.5 \div 10.5 \text{ кВ}; k_z = 0.8 \div 0.85; \cos\varphi = 0.9 \div 0.99.$$

Как видно из указанного набора данных валидационной выборки отличается от них и не принадлежит к указанной генеральной выборке.

Одной из важнейших проблем, возникающих при проектировании ИНС, является выбор ее архитектуры (количество скрытых слоев и количества нейронов в каждом слое) и их обучение (настройка весов и порога). Для решения первой задачи нет никаких жестких правил ни по выбору количества скрытых слоев, ни по выбору количества нейронов в них.

Выбор архитектуры сети, осуществляется, как правило, на основе опыта исследователя. Но при этом существуют ряд общих рекомендаций.

Так при использовании многослойного перцептрана, имеются общие рекомендации по выбору количества слоев на основе теоремы Колмогорова-Арнольда-Хект-Нильсена [4].

Представим основные из них:

- Если функция определена на конечном множестве точек, то трехслойный перцептран способен ее аппроксимировать.
- Если функция непрерывна и определена на компактной области, то трехслойный перцептран способен ее аппроксимировать.
- Остальные функции, которым могут быть обучены нейронные сети, могут быть аппроксимированы четырехслойным перцептроном.

Таким образом, теоретически максимальное количество слоев, которое необходимо – четыре, т.е. с двумя скрытыми слоями.

Обзор по методикам выбора количества нейронов в скрытом слое приведен в [5].

Данные методы можно разделить на аналитически ей конструктивные.

Аналитические – предполагают наличие некоторой математической формулы, а в конструктивных используются два способа: редукция и наращивание. В алгоритмах редукции в качестве исходной точки используется избыточная архитектура сети, которая в процессе обучения упрощается путем исключения наименее значимых нейронов. При наращивании, первоначально в сети нейроны отсутствуют и последовательно добавляются по мере развития процесса обучения.

Данный способ является более целесообразным для выбора количества нейронов в скрытом слое.

После выбора архитектуры сети осуществляется процесс обучения. В частности, для многослойного перцептрана это может быть алгоритм обратного распространения ошибки (backpropagation). Имеются также модификации данного алгоритма, к которым относятся алгоритм быстрого распространения и др. Также имеются алгоритмы второго порядка, такие как метод сопряженных градиентов и метод Левенберга-Марквардта, которые работают существенно быстрее. В качестве метода обучения в большинстве случаев целесообразно выбирать алгоритм Левенберга-Марквардта, и только при значительном увеличении числа связей ИНС может быть рекомендовано использование метода сопряженных градиентов [6].

При выполнении исследований наилучшие результаты даёт сеть с одним скрытым слоем с 8 нейронами. В качестве активационной функции используется гиперболический тангенс. Обучение нейронных сетей выполняется методом Левенберга–Марквардта (Рис.2-3).

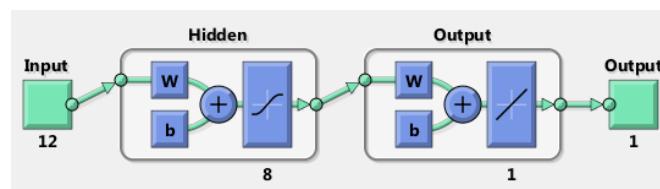


Рис.2. ИНС для подбора кривой (fitnet)

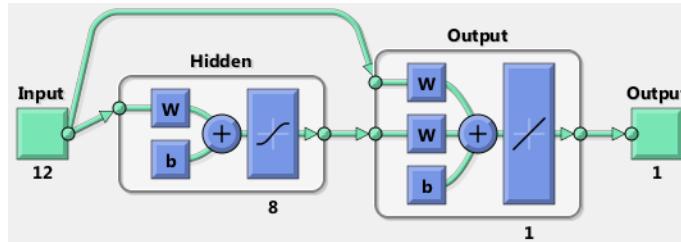


Рис.3. КаскаднаяИНС (cascade-forward net)

Для определения качества моделей будем использовать все указанные выше выборки. В качестве критерия для оценки моделей используется средняя квадратическая ошибка, MSE (Табл.1):

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - Y_{mod,i})^2 \quad (8)$$

где,  $Y_i$  – фактическое значение,  $aY_{mod,i}$  - значение полученное по модели ИНС.

Табл.1. Средняя квадратическая ошибка моделирования

Выборки / расч.время	Ед.изм	Тип модели			
		CFNN	FNN	GMDH	ANFIS
Обучающая	тыс.кВт*ч	0,0003673	0,00000012	0,1727062	0,0057662
Тестовая	тыс.кВт*ч	0,0004713	0,00000031	0,2610916	0,0345099
Валидационная	тыс.кВт*ч	0,0004764	0,00000022	0,1848323	0,0416372
Контрольная	тыс.кВт*ч	0,1370613	0,00009921	2,0218198	0,3073269
Расч.время,	сек	2,64	4,18	2,49	34,22

Для выбора наилучшей модели используется средняя квадратическая ошибка моделирования и коэффициент детерминации на контрольной выборке. Как видно по результатам наилучшей моделью для оценки технических потерь электроэнергии является перцептрон. Результаты оценок для данной сети представлены на Рис.4.

По данному алгоритму были получены модели ИНС для других схем фидеров 6-10 кВ, где наилучшей моделью является ИНС для подбора кривой fitnet. В Табл.2 представлены результаты оценок на контрольной выборке.

Табл.2. Результаты оценок ИНС fitnet на контрольной выборке

№	Данные по схеме РС	MSE	R <sup>2</sup>	Расч.время, сек
1	3 ветви 1 нагрузка	0,00004	0,999	3,25
2	6 ветвей 2 нагрузки	0,0021	0,998	3,52
3	27 ветвей 11 нагрузок	0,1526	0,992	7,88
4	43 ветвей 16 нагрузок	4,2428	0,992	11,93

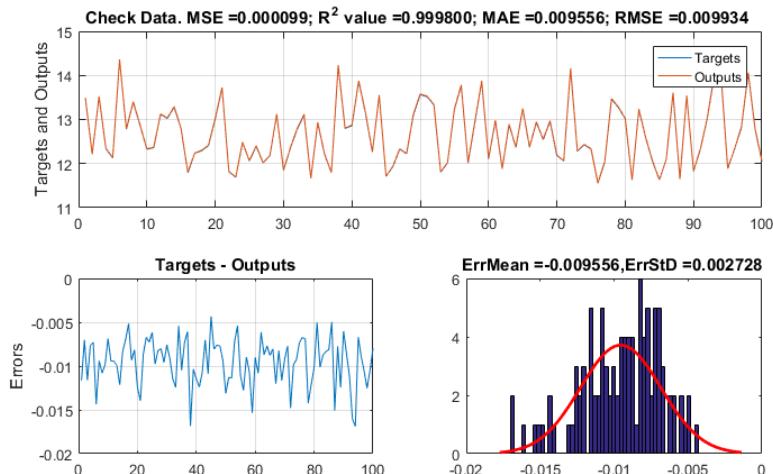


Рис.4. Результаты оценок на контрольной выборке для ИНС fitnet

### Заключение

Применение ИНС для оценки параметров режима является достойной альтернативой (но не заменой) традиционным методам.

По сравнению с классическими методами, обученная ИНС, требует незначительные вычислительные и временные ресурсы, что является весьма важным при выполнении оперативных расчётов.

Из рассмотренных ИНС прямого распространения, по результатам проверок, лучшие результаты даёт перцептрон с одним скрытым слоем с 8 нейронами со средней квадратической ошибкой MSE – 0,000099.

Как показали результаты, погрешность расчета очень маленькая в сетях с меньшим количеством ветвей и нагрузок, а в более сложных сетях она немного увеличивается что свидетельствует об удачно обученной и правильно сформированной ИНС.

### Список литературы:

1. Идельчик В.И. Электрические системы и сети [Electricalsystemsandnetworks]. М: Энергоатомиздат., 1989, 592 с.
2. S. G. Ankaliki. S. G. Gollagi Power System Steady State Monitoring Using Artificial Neural Network. Journal of Engineering and Technology. Jan-Jun 2011. Vol 1. Issue 1. Page: 4-9
3. Muzaffar Khudayarov. Nuriddin Normamatov. Power system steady state calculations using artificial neural networks. E3S Web of Conferences 216. 01102 (2020). RSES 2020.doi.org/10.1051/e3sconf/202021601102
4. Hecht-Nielsen R. “Kolmogorov's Map: Concepts. Algorithms. and Applications. Springer-Verlag. New York. <http://dx.doi.org/10.1007/978-1-4757-2553-7ping> Neural Network Existence Theorem”. Proc. Int. Conf. Neural Networks. v. III. IEEE Press. New York. 1987. 11–14
5. Sheela K. G. Deepa S. N. Review on methods to fix number of hidden neurons in neural networks. Mathematical Problems in Engineering. 2013, 1–11
6. D.V. Vasenkov Methods for training artificial neural networks. Computer tools in education. No. 1. 2007. pp. 20-29