

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ЗАДАЧ ОПЕРАТИВНОГО УПРАВЛЕНИЯ ЭЛЕКТРИЧЕСКИМИ СЕТЯМИ

Заболотный И.П., Селинова Т.И.

Донецкий национальный технический университет

ivp@elf.dgutu.donetsk.ua

Directions of the use of networks of neurons of different type are considered for an operative management the electro energy systems. Realization of gradient method and method of Newton is offered for the multi-layered networks of neurons.

Постановка задачи. Актуальность совершенствования управления электроэнергетическими объектами на современном этапе развития энергетики возрастає из-за изменения условий их функционирования. Структурная перестройка и внедрение энергетического рынка сопровождается не только увеличением числа решаемых технологических задач управления, но и динамичностью ситуаций и взаимосвязью технологических задач разных групп. Для обеспечения надлежащего уровня надежности функционирования электроэнергетических объектов существует настоятельная необходимость совершенствования систем управления, особенно диспетчерского путем разработки новых подходов, в том числе, основанных на методах искусственного интеллекта и принципах адаптивного управления.

Эффективность решения задач оперативного управления электрическими сетями зависит от учета их особенностей, в первую очередь к которым следует отнести требования обеспечения быстродействия в темпе реального процесса, устойчивости процедур решения к изменению погрешностей каналов измерения, приспособленности к работе с плохо обусловленными задачами. Эти особенности влияют на методическое, программное обеспечение и на используемую вычислительную базу, являющимися составляющими процедуры использования искусственного интеллекта в системах управления.

Предварительный анализ последних исследований.

В настоящее время повышение быстродействия вычислительных систем обеспечивается за счет:

- построения и использования многопроцессорных систем параллельной архитектуры;
- разработки и реализации алгоритмов параллельных вычислений на соответствующем аппаратном обеспечении (нейрочипах);
- комбинированного использования генетических алгоритмов и методов минимизации, для которых характерна сверх линейная скорость сходимости. При этом используются упрощенные математические модели (в первую очередь линеаризованные), а решение задач выполняется, как правило, в режиме on-line;
- обеспечения хорошей обусловленности задачи различными методами;
- использования робастных методов, устойчивых к наличию погрешностей в исходной информации;
- обучения нейронной сети вне реального времени, но при обеспечении учета сложной поверхности функции качества и адаптации к изменениям топологии электрической сети и изменению режима;
- использования рекуррентных нейронных сетей типа Хопфилда-Лагранжа, в которых точные измерения учитываются в виде ограничений типа равенств, и многослойных рекуррентных нейронных сетей, в которых реализуется распараллеливание вычислительного процесса и используется преимущественно аналоговая или аналогово-цифровая элементная база с высоким быстродействием.

Задача исследований. Целью настоящей работы является выявление тенденций развития оперативного управления на основе интеллектуальных методов с ориентацией на существующие технические средства с учетом их перспективного развития и на адаптацию составляющих модели к особенностям конкретной технологической задачи и цели управления.

Изложение основного материала. Как следует из значительного числа работ [1-15 и др.], в первую очередь зарубежных авторов, наибольшее распространение в энергетике получили три вида ИНС: многослойные сети прямого распространения, сети Кохонена, рекуррентные сети Хопфильда. Особенности нейросетевого моделирования инициировали множество исследований его применения при решении различных задач оперативного управления ЭЭС, что наиболее полно отражено в [16].

Важным этапом в создании ИНС является ее обучение, которое заключается в настройке параметров ИНС. Вид ИНС определяет особенности обучения.

Обучение многослойных ИНС. В сетях оптимальные выходные значения нейронов всех слоев, кроме последнего, как правило, не известны. В таких условиях обучить многослойный перцептрон невозможно руководствуясь только величинами ошибок на выходах ИНС. Обучение многослойных сетей супервизорное, требующее в обучающей выборке наличия не только множества входных векторов, но и множества соответствующих откликов.

Математическая задача заключается в нахождении таких значений весовых коэффициентов (при фиксированной структуре), чтобы минимизировалась ошибка рассогласования между реакцией сети и требуемым

откликом для всех примеров обучающей выборки. Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образом:

$$\min E(w) = \sum_{i=1}^p E_p = \sum_{i=1}^p \sum_{j=1}^m (y_{ij} - d_{ij})^2, \quad (1)$$

где y_{ij} , d_{ij} – соответственно фактическая и желаемая реакция j -го нейрона выходного слоя на i -й входной вектор, p – число образов (примеров) в обучающей выборке, m – число нейронов в выходном слое.

Информация, закладываемая в ИНС в процессе обучения, должна храниться в межнейронных соединениях – синапсах. Таким образом, обучение заключается в модификации синаптических весов нейронов w_{ij} .

Все существующие методы обучения можно классифицировать на детерминистские и стохастические.

В детерминированных методах используются формулы обратного распространения ошибки, полученные в [17]. В настоящее время разработаны, как различные модификации алгоритма обратного распространения ошибки [18-20], так и более мощные процедуры обучения ИНС, реализующие такие методы поиска, как метод сопряженных градиентов, квазиньютоновские методы и т.п. [21-22].

В первом случае процедура коррекции весов использует информацию о градиенте функции ошибки E и требует дифференцируемости функции активации.

Минимизация функции качества выполняется на основе алгоритма градиентного спуска в пространстве весовых коэффициентов, осуществляемого последовательно для всех образов обучающей выборки

$$\Delta w_{ij}^{(k)}(t) = -\eta \frac{\partial E_p}{\partial w_{ij}^{(k)}}, \quad n = 1, 2, \dots, N, \quad (2)$$

где $w_{ij}^{(k)}$ – весовой коэффициент j – той связи i – го нейрона в слое n , η – скорость обучения, $0 < \eta < 1$; N – число слоев нейронов в сети.

В ряде работ, например [23], показано на основе использования правила дифференцирования сложной функции

$$\frac{\partial E_p}{\partial w_{ij}^{(n)}} = \frac{\partial E_p}{\partial y_i^{(n)}} \frac{\partial net_i^{(n)}}{\partial w_{ij}^{(n)}}, \quad (3)$$

где $y_i^{(n)}$ и $net_i^{(n)}$ – соответственно выходной сигнал и состояние i – го нейрона в слое n ($y_i^{(0)} = x_i$).

После преобразований получен рекурсивный алгоритм коррекции весов, начинающийся на выходных нейронах и возвращающийся к первому слою

$$w_{ij}^{(n)}(t+1) = w_{ij}^{(n)}(t) - \eta \delta_i^{(n)} y_j^{(n-1)}. \quad (4)$$

Дельта ошибки $\delta_i^{(k)}$ i – го нейрона для выходного слоя определяется, как

$$\delta_i^{(N)} = (y_i^{(N)} - d_i) f'(net_i^{(N)}) \quad (5)$$

и затем рекурсивно пересчитываются для всех слоев:

$$\delta_i^{(n)} = f'(net_i^{(n)}) \sum_{j=1}^{h^{(n+1)}} \delta_j^{(n+1)} w_{ji}^{(n+1)}, \quad n=1, 2, \dots, N-1, \quad (6)$$

где $h^{(n)}$ – число нейронов в n -ом слое, $f'()$ – производная функции активации по ее аргументу.

Иногда для придания процессу коррекции весов некоторой инерционности, сглаживающей резкие скачки при перемещении по поверхности целевой функции, выражение (4) для расчета $w_{ij}^{(n)}(t+1)$ дополняется значением изменения веса на предыдущей итерации. Ниже приведен алгоритм обучения ИНС с помощью процедуры обратного распространения (рис. 1):

1. Подать на входы сети один из возможных образов и в режиме обычного функционирования ИНС, когда сигналы распространяются от входов к выходам, рассчитать значения последних.

2. Рассчитать $\delta^{(N)}$ для выходного слоя. Рассчитать изменения весов $\Delta w^{(N)}$ слоя N.
 3. Рассчитать соответственно $\delta^{(n)}$ и $\Delta w^{(n)}$ для всех остальных слоев, $n=1,.., N$.
 4. Скорректировать все веса в ИНС
- $$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t).$$
5. Если ошибка сети существенна, перейти на шаг 1. В противном случае – конец.




Рисунок 1 - Сигналы в сети при обучении

Если производная по функции активации стремится к нулю, то эффективность обучения резко снижается. Такие ситуации могут возникнуть, когда положительные или отрицательные значения весовых коэффициентов сместят рабочую точку на симоидах многих нейронов в область насыщения. Кроме того, применение метода градиентного спуска не гарантирует, что будет найден глобальный, а не локальный минимум целевой функции.

Стochasticеские методы обучения выполняют псевдослучайные изменения значений весов, сохраняя те изменения, которые ведут к уменьшению функции ошибки. Для этого привлекаются методы адаптивного случайного поиска, имитация отжига, генетические алгоритмы и др.

При использовании линеаризованных моделей технологических задач упрощается поверхность функции качества, что влияет на адекватность модели знаний. При ориентации на существующие аппаратные средства управления с учетом их эволюционной модификации перспективным направлением в построении адекватной модели знаний для ИНС является вынос этапа обучения из процедуры управления в реальном времени. В этом случае серьезной проблемой при обучении ИНС реальным задачам становится учет сложной поверхности функции качества. Целесообразно использование методов, приспособленных к минимизации функции качества, для которой характерно наличие оврагов и много экстремальности. Одним из возможных направлений решения такой задачи является использование метода оптимизации второго порядка – шарового метода Ньютона [21]. Более качественные показатели обучения ИНС получаются при реализации шарового алгоритма в качестве алгоритма наказания. Для определения возбуждения и торможения в случаях большого числа параметров и выходных сигналов используется понятие порядка в векторных пространствах, который задается с помощью замкнутого выпуклого телесного двойного конуса Q, в котором лежит множество всех шаров. Конус представляется в виде функционального элемента f с входными параметрами и параметрами α , определяющими шары. В [24] разработан метод обучения ИНС на основе шарового метода Ньютона. На рис. 2-3 приведена схемная реализация метода, который реализуется в ИНС моделирования оперативного управления электрическими системами.




Рисунок 2 – Тakt прямого функционирования с вычислением частных производных

На вход ИНС подаются значения переменных $x_i (i=1, \dots, n)$. На каждом шаге вычисляется функция $f_j (j=n+1, \dots, N)$. На выходе сети при данных значениях параметров получается сложная функция $F(a, x)$. Схема вычисления $dF/dx_i, dF/da_i$ будет состоять из двух цепочек – прямой (рис. 2) и обратной (рис. 3). Цепочка прямого функционирования, помимо вычисления, f_j , будет включать еще вычисление частных производных этих функций по их аргументам: f_j, k — производная f_j по k -му аргументу (входу), f_j, a_m — производная f_j по a_m .

В ходе обратного функционирования вычисляются производные dF/dx_i . При организации обучения используются вторые производные функции ошибки. Обеспечивается вычисление градиентов от некоторых функций градиента H в параллельно-последовательном режиме сетью автоматов прямого и обратного функционирования, т.е. реализовано дважды обратное функционирование называемое "back-back" процедурой.




Рисунок 3 – Такт обратного функционирования ИНС

В настоящее время интенсивно развивается подход распараллеливания вычислительного процесса за счет отображения задачи на двухслойную рекуррентную нейронную сеть. Этот подход обеспечивает повышение быстродействия решения задачи при робастном оценивании состояния электроэнергетических систем. Одной из проблем, связанных с применением рекуррентных нейронных сетей, является обеспечение устойчивости ИНС. В ряде работ доказана устойчивость одно и двухслойных сетей класса Хопфилда, используемых для линейного и квадратичного программирования и показана возможность работы ИНС при наличии ошибок по части входов.

Выводы.

1. Выполнен анализ использования ИНС для оперативного управления электроэнергетическими системами. Показаны направления повышения быстродействия систем управления и проблемы их построения.

2. Предложен алгоритм обучения ИНС с помощью процедуры обратного распространения в рамках реального времени оперативного управления ЭЭС.

3. Показана возможность использования шарового метода оптимизации Ньютона на этапе обучения ИНС при решении задач оперативного управления ЭСС. Основной объем вычислений, связанный с обучением ИНС, выносится за контур реального времени, тогда как в режиме on-line формируется мгновенный отклик - решение. Это удовлетворяет главному требованию работы в цикле оперативного управления - жестким ограничениям реального времени. По сравнению с существующими традиционными методами оптимизации этот метод обладает следующими преимуществами: позволяет получить хорошее начальное приближение при решении задач нелинейного оценивания; обладает квадратичной скоростью сходимости; дает возможность отыскания экстремума функций многих переменных, обладающих множеством локальных минимумов, поверхности уровня которых имеют овражную структуру.

ЛИТЕРАТУРА

- 1 Peng T.M., Hubale N.F., Karady G.G.. Conceptual approach to the application neural networks for short-term load forecasting // IEEE Int. Symp. Circuits and Syst. - 1990. - vol.4. - P. 2942-2945.
2. Kottathra K., Pryor T.L, Cole G.R., Cheok K. Load Forecasting for remote area power supply systems. //The 11th Conference on Artificial Intelligence for Applications (Car.No.95CH35758), Los Angeles, CA, USA, 20-23 Feb. 1995 (Los Alamitos, CA, USA: IEEE Comput. Soc. Press 1995) - P. 231.
3. Bakirtzis A.G. and oth. Short term load Forecasting Using Fuzzy neural networks // IEEE Power Eng. Review. 1995. - vol.10. - N3.
4. Kwang-Ho Kim. Implementation of Hybrid short-term load Forecasting System Using Artificial Neural Networks and Fuzzy Expert systems // IEEE Power Eng. Review. - 1995. - vol.10. - N3.
5. Bakirtzis A.G. and oth. A neural network short term load forecasting model for the Greek Power system // IEEE Trans. on Power Systems. - 1996. - vol.11. - N2.
6. Simo J.B., Kamwa I.. Exploratory Assessment of the Dynamic Behavior of Multimachine System Stabilized by a SMES Unit // IEEE Power Eng. - 1995.
7. King T.D. and oth. Optimal environmental dispatching of electric power systems via an improved Hopfield neural network model // IEEE Trans on Power Systems. - 1995. - v.10. - N3.
8. Sidhu, T.S., Ao Z. On-line Evaluation of capacity and Energy Losses on Power Transmission Systems by using Artificial neural networks // IEEE Trans. on Power Delivery. -1995. - v.10. - N4.
9. Bernieri A., Betta G.. Neural network and psevno-measurements for real-time monitoring of distribution systems // IEEE Trans. on Instrumentation and measurement. - 1996. - v.45. - N2.
10. Park Y.M. and oth. A neural-network based Power system stabilizer ising Power Flow Characteristics // IEEE Trans. on Energy Conversion. - 1996. - v.11. - N2.
11. Hayashi Y. and oth. Efficient Determination of optimal Radial power system structure using Hopfield neural network with Constrained noise // IEEE Trans. on Power Delivery.-1996.-v.11-N3.
12. Fushuan W., Zhenxiang H. A kind of generalized Hopfield continuons model and its application to the optimal distribution of reactive sources in power systems. Artificial neural network (ed. T.Kohonen) 1991.
13. Hiyama T. and oth. Evaluation of neural networks based Re-al time maximum power tracking Controller for PV system // IEEE Trans. on Energy Conversion. - 1995. - v.10. - N3.
14. Чукреев Ю.Я., Хохлов М.В., Готман Н.Э. Применение искусственных нейронных сетей в задачах оперативного управления режимами электроэнергетических систем - Сыктывкар: Коми НЦ УрО РАН. - Вып. 56, 2000. 24 с.
15. Чукреев Ю.Я., Хохлов М.В., Алла Э.А. Оперативное управление режимами региональной энергосистемы с использованием технологии искусственных нейронных сетей //Электричество.- 2000 .№4.-С. 2-10.
16. Neubor D.et al. Artificial neural networks for power systems/ CIGRE TF 38.06.06 // Electra. - 1995. - №159. - P. 77-101.
17. Rumelhart D.E., Hinton G.E., Williams R.J. Learning integral representations by error propagation // Parallel Distributed Processing. - 1986. - Vol. 1. - № 8. - P. 318-362.
18. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика. - М.: Мир, 1992. - 240 с.
19. Lippmann R.P. An introduction to computing with neural nets // IEEE ASSP Magazin, April. - 1987. - P.4-20.
20. Pandua A.S., Macy R.B. Pattern recognition with neural networks in C++. Boca Raton: CRC Press: 1996. - 410 p.
21. Горбань А. Н. Обучение нейронных сетей. М.: СП ПараГраф, 1990. - 159 с.
22. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. Новосибирск: Наука. Сибирск. издательская фирма РАН, 1996. - 276 с.
23. Sankar K. Pal, Sushmita Mitra, Multilayer Perceptron, Fuzzy Sets, and Classification //IEEE Transactions on Neural Networks. - 1992. - Vol.3. - N5. - P. 683-696.
24. Бондарев П. А., Прокурик Р.А. Обучение нейросети на базе шарового метода оптимизации Ньютона // Инженерное образование. - 2005. - №6.

Рекомендовано проф., д.т.н. Сивокобыленко В.Ф.