УДК 615.1.3

Ходаковский Н.И.,
к.т.н., с.н.с.,
Институт кибернетики им. В.М. Глушкова НАНУ
Кузьменко Б.В.,
д.т.н., профессор,
Академия муниципального управления

ИССЛЕДОВАНИЕ МОДЕЛИ ПАМЯТИ СИНАПТИЧЕСКИХ СТРУКТУР НА ПРИНЦИПАХ РАБОТЫ НЕЙРОНЕЧЕТКИХ СЕТЕЙ

На основе механизмов высокопроизводительных вычислений в биосистемах исследованы возможности обработки данных в синаптических сетях на принципах работы нейронечетких сетей. Использован естественный параллелизм нейронных сетей в биосистемах для последовательных вычислений в известных информационных технологиях. Рассматриваемые в работе методы обработки данных в синаптических структурах на принципах работы нейронечетких сетей с использованием программных агентов очень важны для построения системах обучения.

Ключевые слова: моделирование памяти, синаптические сети, нейронечеткие сети, информационные технологии.

Ходаковський М.І.,
к.т.н., с.н.с.,
Інститут кібернетики ім. В.М. Глушкова НАНУ
Кузьменко Б.В.,
д.т.н., професор,
Академія муніципального управління

ДОСЛІДЖЕННЯ МОДЕЛІ ПАМ'ЯТІ СИНАПТИЧНИХ СТРУКТУР НА ПРИНЦИПАХ РОБОТИ НЕЙРОНЕЧІТКИХ МЕРЕЖ

На основі механізмів високопродуктивних обчислень в біосистемах досліджені можливості обробки даних в синаптичних мережах на принципах роботи нейронечітких мереж. Використаний природний паралелізм нейронних мереж в біосистемах для послідовних обчислень у відомих інформаційних технологіях. Розглянуті в роботі методи обробки даних в синаптичних структурах на принципах роботи нейронечітких мереж з використанням програмних агентів дуже важливі для побудови системах навчання.

Ключові слова: моделювання пам'яті, синаптичні мережі, нейронечіткі мережі, інформаційні технології.

Khodakovsky N.I.
Ph.D., Senior Scientist,
Institute of Cybernetics. VM Glushkov NASU

Kuzmenko B.V.
Professor,
Academy of Municipal Administration

STUDY MEMORY MODEL SYNAPTIC STRUCTURES AT WORK PRINCIPLES NEURO NETWORKS

High-performance computing mechanisms in biological systems studied data processing capabilities in synaptic networks work on the principles of neuro-fuzzy networks was based. The natural parallelism of neural networks in biological systems for sequential computations in the known information technology was used. In this paper methods of data processing in the synaptic structures on the principles of neuro-fuzzy networks work using software agents are very important to build a system of education considered.

Keywords: modeling memory, synaptic network, fuzzy neural network, information technologies.

Введение. Заимствование архитектурных принципов биосистем привело к разработке теорий нейронных сетей и нечетких множеств с применением последних в технических системах. На основе методов нечетких вычислений, которые основываются на знаниях экспертов, решаются задачи в условиях неполной достоверности и неопределенности информации, а также выполняются распределенные вычисления при решении нечетких и трудно формализуемых задач. Внимание разработчиков информационных технологий (ИТ) и нейронных сетей (НС) при этом было обращено на естественный параллелизм НС в биосистемах по сравнению с последовательными вычислениями, свойственными большинству известных систем ИТ. Немаловажными факторами, способствующими распространению нейросетевых вычислений, являются такие свойства НС, как адаптивность, высокая информационная защищенность, способность выделения и классификация скрытых в информации знаний. Как известно [1], биосистемы обладают многоуровневой иерархической системой жизнеобеспечения, реализованной с использованием комплекса механизмов информационной избыточности, надежности и иммунитета.

Постановка задачи. На основе использования механизмов высокопроизводительных вычислений, подобных производимых мозгом, необходимо исследовать возможности создания высокопараллельной архитектуры синаптических сетей на принципах работы нейронечетких сетей.

Представление синаптических связей в форме нечеткого избыточного распределенного информационного поля.

Исходя из того, что для НС свойственно нечеткое представление данных, возможно представление данных в виде некоторой окрестности, нахождение значений в которой не вызывает изменения реализуемой НС функции. Информация в виде системы взвешенных межнейронных связей представляется в избыточной распределенной по НС форме, а искажение оперативных и долговременных данных не приводит к утрате работоспособности НС. В процессах работы и адаптации НС участвует не локальная связь, а вся система межнейронных связей в форме нечеткого избыточного распределенного информационного поля НС.

Высокая производительность систем ИТ при решении задач, характеризующихся нечеткой, недостоверной информацией, нерегулярными процессами обработки с изменяющимися в процессе эксплуатации системы составом и взаимосвязями компонентов, может обеспечиваться параллелизмом нейросетевых вычислений и управлением потоком данных (УПД), а также инструментарием нечеткой логики [2].

Модель адаптивной реализации ресурсов вычислений в данной работе использует принцип биосистемной аналогии, в частности, иерархию системы защиты информационных процессов и ресурсов в биологической системе, согласно которой на нижних уровнях иерархии задействованы механизмы иммунной системы, а на верхних - механизмы адаптивной памяти и накопления жизненного опыта нервной системы [1].

Построение модели адаптивной реализации ресурсов вычислений. Основным механизмом реализации адаптивных свойств можно считать способность нечеткого распределенного информационного поля нейронной сети к накоплению знаний в процессе обучения.

Вторым по важности механизмом с точки зрения адаптивной модели является нечеткий логический вывод, который базируется на нечетком представлении информации в НС и позволяет использовать опыт экспертов, овеществленный в виде системы нечетких предикатных правил, для предварительного обучения нейронечеткой сети. Возможность отображения системы нечетких предикатных правил на структуру НС и последующее ее обучение позволяют не только устранить противоречивость исходной системы нечетких предикатных правил, но и дает возможность проанализировать сам процесс логического вывода с целью дальнейшего уточнения существующей или синтеза новой системы нечетких предикатных правил адаптивной НС.

Третьим механизмом, необходимым для реализации адаптивных НС, является способность нейронных и нейронечетких сетей к классификации и кластеризации.

Рассмотрим алгоритм нечеткого логического вывода при обработке входного образа в нечетких НС. Нечеткие НС сочетают достоинства нейросетевых НС и нечетких логических систем, опирающихся на априорный опыт в виде заданной системы нечетких предикатных правил. Механизм нечетких выводов основан на базе знаний, формируемой специалистами предметной области в виде системы нечетких предикатных правил вида:

П : если x есть $Л_1$, то y есть $В_1$,

$П_2$: если x есть $Л_2$, то y есть B_2,

$П_n$: если x есть $Л_n$, то y есть $B_п$,

где x и y, соответственно, входная переменная и переменная вывода, а $Л_1$ и B_t - функции принадлежности семантических данных.

Нечеткое отношение $R = Л \wedge B$ отражает знания эксперта $Л \wedge B$ в виде причинного отношения предпосылки и заключения, где операция ^ соответствует нечеткой импликации. Отношение R можно рассматривать как нечеткое подмножество прямого произведения X x Y полного множества угроз X и механизмов защиты Y, а процесс получения нечеткого результата вывода В по предпосылке Л и знаниям $Л \wedge B$ - в виде композиционного правила: $B = Л \bullet R = Л \bullet (Л \wedge B)$, где • - операция, например, max-min- композиции [3].

Логический вывод, как правило, включает следующие этапы [2]:

1) Введение нечеткости (fuzzification): по функциям принадлежности, заданным на области определения входных нечетких правил (НП), исходя из фактических значений НП, назначается степень истинности для каждого правила;

2) Логический вывод: по степени истинности входных образов формируются заключения по каждому из правил, образующие нечеткое подмножество для каждого фрагмента НС;

3) Композиция: полученные на этапе 2 нечеткие подмножества для каждого этапа заключения объединяются с целью формирования нечеткого подмножества для всех этапов заключения (по всем правилам);

4) Приведение к четкости (defuzzification): сводится к преобразованию нечеткого набора выводов по всем правилам в четкое значение итоговой НС.

Рассмотрим этапы логического вывода для системы нечетких правил:

$П_1$: если x есть A , то w есть D,

$П_2$: если y есть B , то w есть E,

$П_3$: если z есть C , то w есть F,

где x, y и z - входные НП, соответствующие известным входным образам, w - НП вывода, соответствующая итоговому заключению системы, а A, B, C, D, E, F- функции принадлежности семантических данных.

Вначале на основании значений непрерывных переменных по семантикам A, B, C находятся степени истинности $a(x_0) = A(x_0)$, $a(y_0) = B(y_0)$, и $a(z_0) = C(z_0)$ входного образа для каждого из нечетких предикатных правил. На втором этапе операцией min в соответствии со степенью истинности $a(x_0)$, $a(y_0)$, и $a(z_0)$ удаляются верхние части семантик D, E и F, формируются заключения по каждому из правил, образующие нечеткое подмножество для каждого входного образа. На третьем этапе операцией

max производится объединение усеченных семантик и формирование комбинированного нечеткого подмножества, описываемого семантикой (w) и соответствующего логическому выводу для выходной переменной *w* итогового заключения системы ИТ. На четвертом этапе определяется значение выходной непрерывной переменной, например, с использованием центроидного метода находится центр тяжести w_0 для кривой (w) [1].

В механизме классификации заключений целесообразно использовать сочетание возможностей НС и нечеткой логики. Нейронные сети и системы с нечеткой логикой имеют специфические особенности: с одной стороны, возможность обучения НС, а с другой, процесс решения задач системами с нечеткой логикой прозрачен для объяснения получаемых выводов. Объединение двух подходов в нечетких НС позволяет сочетать достоинства нейросетевых и нечетких логических систем, опирающихся на априорный опыт специалистов. Как следует из опыта разработки нечетких НС [2] для целей классификации реализуют нейронечеткие сети, которые решают задачу отнесения нечеткого входного вектора к четкому классу, а также нейронечеткие сети, применяющие построения нечетких систем нечетких правил вывода.

Рассмотрим подход к организации нейронечеткого классификатора, использующего механизм нечеткого логического вывода для классификации исходных заключений по нечетким векторам входных образов нейронной сетью с нечеткими связями [4]. На рис.1 приведена схема прогнозного поиска образа с использованием нейронечетких сетей.

На рис.1обозначены: БЗ – базы знаний существующих кластеров данных, ВО – входящие образы, КНД – кластеры с нечеткими данными, МП – методы поиска или прогнозирования, РНЭ – разделение нечетких элементов на группы, ККНД- классификатор кластеров с нечеткими данными, МГНЭ – модели групп с нечеткими элементами, ОС – ответ системы в виде найденного образа.

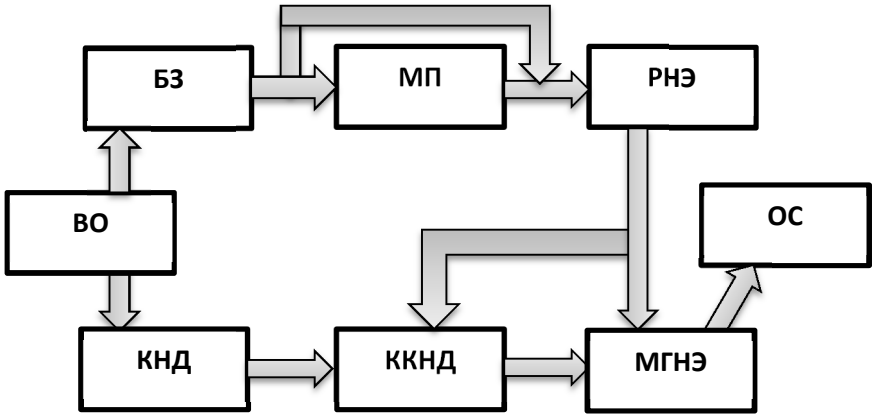

Рис.1. Схема прогнозного поиска образа с использованием нейронечетких сетей.

В работе нейронечеткого классификатора (рис.1) используются следующие этапы. На первом этапе осуществляется формирование обучающей выборки. 1.1. Сравнение входного образа с базой знаний существующих кластеров данных. 1.2. Формируем с базы знаний (1.1) некоторое количество элементов путем создания случайной выборки. 1.3. Исследуем характер нечеткой информации, подвергающейся прогнозированию. 1.4. Используя полученные оценки по (1.3) и фрагмент базы знаний (1.2) формируем обучающую выборку. 1.5. Повторяем шаги 1.2–1.4 до тех пор, пока объем обучающей выборки не будет достаточным (число экземпляров больше некоторого заданного числа прогнозных элементов).

Этап 2. Создание управляющего элемента в виде классификатора кластеров с нечеткими данными. 2.1. Определяем группы элементов массива с нечеткими данными с существующими кластерами данных в (1.1). 2.2. Строим и обучаем управляющий элемент – классификатор прогнозных элементов на основе классификатора кластеров с нечеткими данными. Основная идея классификатора заключается в том, чтобы по известной части экземпляра, определить ту группу элементов (2.1), к которой принадлежит исследуемая группа в данном случае. Для обучения используем массив случайной выборки (1.2).

Этап 3. Обучение управляющего элемента в виде классификатора кластеров с нечеткими данными. Для обучения используем часть выборки, сформированной на этапе 1.2 и соответствующей группе прогнозируемых элементов,

Этап 4. Прогнозирование значений изучаемых кластеров информации. Указанный кластер подается на управляющий элемент, реализованный на основе классификатора. Управляющий элемент принимает решение о том, какую группу данных, полученных в 1.4, использовать для данного кластера.

Построение модели базы знаний на основе принципов нечеткой логики в четырехслойной нейронной сети.

Используемая в различных видах систем модель на основе нечеткой логики представляет собой базу знаний, построенную специалистами предметной области как множество нечетких правил вида:

$П_1$ если x есть A_1, то y есть B_1 ,

$П_2$ если x есть A_2, то y есть B_2,

...

$П_n$ если x есть A_n, то y есть B_n,

где x и y- входная и выходная переменная соответственно, а A и B-функции принадлежности [6].

Нечеткий логический вывод при обработке входного образа формируется в несколько шагов:

- введение нечеткости: на этом этапе функции принадлежности применяются к фактическим значениям входных переменных;
- логический вывод: вычисляется значение истинности для предпосылок каждого правила и применяется к заключениям каждого правила. Это приводит к одному нечеткому подмножеству, которое будет назначено каждой переменной вывода для каждого правила;
- композиция: нечеткие подмножества, назначенные каждой переменной вывода, объединяют в одно множество для всех переменных вывода;
- приведение к четкости: используется в случаях, когда необходимо преобразовать нечеткий набор выводов в четкое число.

На этих принципах построено большое количество сетей, рассмотрим подробнее одну из них - сеть Ванга – Менделя [6]. Структура такой сети представляет собой четырехслойную нейронную сеть, в которой первый слой выполняет фазификацию входных переменных, второй - агрегирование значений активации условия, третий - агрегирование М правил вывода (первый нейрон) и генерацию нормализующего сигнала (второй нейрон), тогда как состоящий из одного нейрона выходной слой осуществляет нормализацию, формируя выходной сигнал [6].

В этой сети первый и третий слой являются параметрическими: первый слой содержит $M*N*2$ параметров функции Гаусса, а третий - М параметров w_i.

Выходной сигнал сети Ванга - Менделя рассчитывается по формуле:

$$y(x)=\frac{\sum_{i=1}^{M} w_i \prod_{j=1}^{N} \mu_{ij}(x_j)}{\sum_{i=1}^{M} \prod_{j=1}^{N} \mu_{ij}(x_j)}, \qquad (1)$$

где w_i - весовой коэффициент, $\mu_{ij}()$ - функция Гаусса с параметрами математического ожидания, которое определяет центр c_{ij} и параметрами разброса, которые определяются средним квадратическим отклонением d_{ij},

$$\mu_{ij}(x_j)=\frac{1}{1+\frac{(x_j-c_{ij})^2}{d_{ij}^2}}$$ - функция Гаусса.

Задача сети состоит в построении такого отображения пар данных (x, d), чтобы ожидаемое значение, соответствующее входному вектору x,

формировалось выходной функцией *y(x)*. Обучение нечетких сетей, также как и классических сетей, может проводиться по алгоритму с учителем, основанному на минимизации целевой функции, задаваемой с использованием евклидовой нормы как

$$E = \frac{1}{2}\sum_{l=1}^{p}\left(y(x^{(l)}) - d^{(l)}\right)^2, \qquad (2)$$

где *p* - количество обучающих пар (*x, d*).

Для обучения нечеткой нейронной сети применяют алгоритм, включающий последовательное чередование следующих шагов:

- для фиксированных значений параметров c_{ij} и d_{ij} первого слоя вычисляются значения параметров w_i третьего слоя сети;
- при зафиксированных значениях параметров w_i третьего слоя уточняются параметры c_{ij} и d_{ij} первого слоя сети.

Таким образом, на первом этапе для *K* обучающих выборок $<X^k, d^k>$, k=1, 2, ... *K*, получаем систему *K* линейных уравнений $PV*W = D$, где *W* - вектор, составленный из линейных коэффициентов w_i, *D* - вектор эталонных ответов сети:

$$PV_i^k = \frac{\prod_{j=1}^{N}\mu_{ij}(x_j^k)}{\sum_{i=1}^{M}\prod_{j=1}^{N}\mu_{ij}(x_j^k)}. \qquad (3)$$

Количество строк *K* матрицы *PV* значительно больше количества ее столбцов. Решение этой системы линейных алгебраических уравнений может быть получено за один шаг следующим образом: $W = PV^+ * D$, где PV^+ - псевдообратная матрица для матрицы *PV*.

На втором этапе фиксируются значения коэффициентов полиномов третьего слоя и осуществляется уточнение (обычно многократное) коэффициентов функции Гаусса для первого слоя сети стандартным методом градиента:

$$c_{ij}^{k+1} = c_{ij}^k - v_c\frac{\partial E^k}{c_{ij}^k}, \quad d_{ij}^{k+1} = d_{ij}^k - v_d\frac{\partial E^k}{d_{ij}^k}, \qquad (4)$$

где *k* - номер очередного цикла обучения, v_c - скорость обучения для коэффициентов c_{ij}, v_d - скорость обучения для коэффициентов d_{ij}, $E = \frac{1}{2}\sum_{l=1}^{L}(y_l - y_l^d)^2$ - ошибка сети, где L - общее число обучающих выборок, y_l-

выход сети Ванга-Менделя для данной выборки, y_i^e - эталонное значение выхода сети Ванга - Менделя [5,6].

Производные $\frac{\partial E}{\partial c_{ij}}$ и $\frac{\partial E}{\partial d_{ij}}$ вычисляются по формулам:

$$\frac{\partial E}{\partial c_{ij}} = \sum_{i=1}^{k}(y_i - y_i^e) * \frac{\partial y_i}{\partial c_{ij}}, \quad \frac{\partial E}{\partial d_{ij}} = \sum_{i=1}^{k}(y_i - y_i^e) * \frac{\partial y_i}{\partial d_{ij}}. \tag{5}$$

Производные $\frac{\partial y}{\partial c_{ij}}$ и $\frac{\partial y}{\partial d_{ij}}$ можно найти по формулам:

$$\frac{\partial y}{\partial c_{ij}} = \frac{2*(x_i - c_{ij})*\prod_i \mu_{ij}(x_i)*\sum_j((w_j - w_j)*\prod_i \mu_{ij}(x_i))}{d_{ij}^2(\sum_j \prod_i \mu_{ij}(x_i))^2},$$

$$\frac{\partial y}{\partial d_{ij}} = \frac{2*(x_i - d_{ij})^2*\prod_i \mu_{ij}(x_i)*\sum_j((w_j - w_j)*\prod_i \mu_{ij}(x_i))}{d_{ij}^3(\sum_j \prod_i \mu_{ij}(x_i))^2}, \tag{6}$$

где $\mu_{ij}(x_i)$ - функция Гаусса

Поскольку в череде этапов этап уточнения параметров функции Гаусса имеет много меньшую скорость сходимости, то в ходе обучения реализацию этапа 1, как правило, сопровождает реализация нескольких этапов 2.

Заключение. На основе использования механизмов высокопроизводительных вычислений в биосистемах исследованы возможности обработки данных в синаптических сетях на принципах работы нейронечетких сетей. Показано, что каждый тип архитектуры интеллектуальных систем обладает своими особенностями в части обучения сети, обработки данных и вычисления конечного результата, что, в свою очередь, позволяет использовать одни типы архитектур для решения только определенных задач. Нейронные и синаптические сети могут самостоятельно получать данные и обрабатывать их, однако, процесс обучения сетей занимает много времени, а анализ полученной информации достаточно сложен. При этом, ввод в нейронную сеть какой-либо заранее достоверной информации не возможен. В случае систем, построенных на нечеткой логике, данные, получаемые на выходе таких систем не требуют дополнительной обработки, однако, такие системы не могут самостоятельно получать информацию.

Рассматриваемые в работе методы обработки данных в синаптических структурах на принципах работы нейронечетких сетей могут использоваться при создании нечетких нейронных сетей использованием

программных агентов в системах обучения последних. Такие сети строят решение на основе аппарата нечеткой логики, однако функции принадлежности настраиваются с помощью алгоритмов обучения искусственных нейронных сетей. Кроме того, такие сети не только могут обучаться, но и способны учитывать априорную информацию. По своей структуре нечеткие нейронные сети схожи с многослойными сетями, например, с сетью, обучающейся по алгоритму обратного распространения ошибки.

Использованные источники информации:

1. Нестерук Ф. Г. Безопасное хранение данных в нейросетевых информационных системах // Изв. вузов. Приборостроение. 2003. Т.46, № 7. С. 52-57.
2. Яхъева Г.Э. Нечеткие множества и нейронные сети. – М.: Интернет-Университет Информационных технологий: БИНОМ. Лаборатория знаний, 2006. – 316 с.
3. Нестерук Г. Ф., Нестерук Ф. Г. Организация параллельной обработки данных в многофункциональной памяти // Омский научный вестник. 2000. Вып. 10. С.100 - 104.
4. Halkidi M., Batistakis Y., Vazirgiannis M. On Clustering Validation Techniques // Journal of Intelligent Information Systems. 2003.- 17:2/3.- P. 107–145.
5. Jang J.-S. R. ANFIS: adaptive-network-based fuzzy inference system // Systems, Man and Cybernetics, IEEE Transactions on 1993. Vol. 23. Issue: 3. P. 665–685.
6. Мищенко В.А., Коробкин А.А. Принципы нечеткой логики на примере нечетких нейронных сетей // Современные проблемы науки и образования. - 2012.- Р.11-17.

References:

1. Nesteruk F. G. Bezopasnoe hranenie dannyh v nejrosetevyh informaci¬onnyh sistemah // Izv. vuzov. Priborostroenie. 2003. T.46, № 7. S. 52-57.
2. Jah'eva G.Je. Nechetkie mnozhestva i nejronnye seti. – M.: Internet-Universitet Informacionnyh tehnologij: BINOM. Laboratorija znanij, 2006. – 316 s.
3. Nesteruk G. F., Nesteruk F. G. Organizacija parallel'noj obrabotki dannyh v mnogofunkcional'noj pamjati // Omskij nauchnyj vestnik. 2000. Vyp. 10. S.100 - 104.
4. Halkidi M., Batistakis Y., Vazirgiannis M. On Clustering Validation Technijaues // Journal of Intelligent Information Systems. 2003.- 17:2/3.- R. 107–145.
5. Jang J.-S. R. ANFIS: adaptive-netshhork-based fuzzy inference system // Systems, Man and Cybernetics, IEEE Transactions on 1993. Vol. 23. Issue: 3. P. 665–685.
6. Mishhenko V.A., Korobkin A.A. Principy nechetkoj logiki na primere nechetkih nejronnyh setej // Sovremennye problemy nauki i obrazovanija. - 2012.- R.11-17.

Рецензент: Кисельов В.Б.