

Нейроинформатика, её приложения и анализ данных

XXIII Всероссийский семинар

**Красноярск
2015**

Министерство образования и науки РФ
Сибирское отделение РАН
Российская ассоциация нейроинформатики
Институт вычислительного моделирования СО РАН

НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ

МАТЕРИАЛЫ
ДВАДЦАТЬ ТРЕТЬЕГО ВСЕРОССИЙСКОГО СЕМИНАРА
25 – 27 сентября 2015 года

Красноярск 2015

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXIII Всероссийского семинара, 25 – 27 сентября 2015 г. / Под ред. А.Н.Горбаня, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2015. – 157 с.

В сборнике представлены материалы XXIII Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 25 – 27 сентября 2015 г.

Основной задачей конференции является всесторонний и высоко квалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.

Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.

Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.

Редакционная коллегия:

Горбань Александр Николаевич – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2015

© Коллектив авторов, 2015

ISBN 978-5-906455-07-9



9 785906 455079

МОДЕЛЬ ВОСПРОИЗВЕДЕНИЯ ДВИЖЕНИЯ РОБОТА ПО ТРАЕКТОРИИ НА ОСНОВЕ ИЕРАРХИЧЕСКОЙ ИМПУЛЬСНОЙ НЕЙРОННОЙ СЕТИ

А.В.Бахшиев, Ф.В.Гунделах

Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК), alexab@rtc.ru

Введение

Одним из направлений в исследовании путей создания робототехнических систем (РТС) с когнитивными функциями является построение моделей управления движением подобных по своей структуре биологическим [1,2,3]. В работе предлагается подход, в основе которого лежит модель многоуровневой неоднородной нейронной сети (НС) на импульсных нейронах. Архитектура слоев такой нейронной сети частично основана на структуре биологических НС управления мышечным сокращением.

На рис. 1 представлены уровни иерархии предлагаемой модели.




Рис. 1. Структурная схема уровней нейросетевой системы управления

Здесь:

$y^{(s)}$ - данные с датчиков о текущем положении объекта управления;

$u^{(rcn)}$ - управляющее воздействие на объект;

$y^{(rcn)}$ - выходные данные регулятора описанные ниже;

$y^{(a)}$ - вектор выходных значений афферентных нейронов, соответствующий информации с датчиков о текущем положении объекта управления;

$y^{(m)}$ - вектор активности мотонейронов, предоставляющий информацию о текущем целевом положении объекта управления;

$u^{(pcn1)}$ - вектор управляющих воздействий на регулятор, активирующий необходимые мотонейроны для перехода в новое положение;

$y^{(pcn1)}$ - вектор текущего положения элемента исполнительской системы робота из множества заранее обученных возможных положений;

$u^{(pcn2)}$ - вектор желаемого положения элемента исполнительской системы робота из множества заранее обученных положений;

$y^{(pcn2)}$ - вектор текущего согласованного положения всех элементов робота из множества заранее обученных согласованных положений;

$u^{(tcn)}$ - вектор желаемого согласованного положения;

$y^{(tcn)}$ - вектор описывающий текущую выполняемую роботом траекторию движения;

$u^{(top)}$ - вектор задания желаемой траектории движения из множества заранее обученных траекторий.

Уровень регулятора предоставляет информацию о текущем положении объекта управления (например, звена манипулятора) и обеспечивает переход в заданное положение. Модель регулятора (regulatory control network – RCN) была представлена ранее в работах [4,5]. При этом мы подразумеваем, что с точки зрения системы управления имеется конечный набор возможных положений, их число определяется структурой НС регулятора.

В работе [6] представлено описание нейронной сети позиционирования (position control network – PCN), обеспечивающей согласованное позиционирование элементов исполнительской системы робота. Эта нейронная сеть представлена на схеме дважды. Сеть PCN1 обеспечивает возможность запоминания и воспроизведения (через управление регулятором) конкретных положений отдельного элемента управляющей системы робота. Сеть PCN2 объединяет набор сетей PCN1 для обеспечения собственно согласованного управления всей исполнительской системой. При этом PCN2 в свою очередь предоставляет возможность запоминать и воспроизводить конечное множество совместных положений всех элементов РТС.

Следующим этапом предполагается разработка нейронной сети управления движением по траектории (trajectory control network – TCN), что позволит на последующих уровнях управления, добавив информацию от дополнительных сенсоров, моделировать реакцию робототехнической системы подобно простым условным рефлексам, а затем и все более сложным рефлексам, получаемым как комбинация простых.

Архитектура нейронной сети управления движением по траектории

Как было показано в работе [6] нейронная сеть PCN в качестве входных данных с низшего уровня получает данные от афферентных нейронов регулятора, которые предоставляют информацию о текущем положении элементов исполнительской системы, а также данные активности мотонейронов, по активности которых можно сделать вывод об ожидаемом целевом положении всех исполнительных элементов робота. С высшего уровня сеть PCN получает информацию о целевом положении отдельных исполнительных элементов, а также их целевом согласованном положении. Выходом PCN является информация о текущем положении каждого элемента и текущем согласованном положении.

Архитектура сети PCN не позволяет обеспечить управление движением по траектории, поскольку в ней не содержится информация о предыдущих положениях системы и требуемых последующих, а также отсутствует механизм переключения между положениями.

Для решения этой проблемы был разработан вариант сети TCN, структурная схема которой представлена ниже (рис.2). При этом под движением по траектории мы понимаем последовательную смену положений, из множества, которым располагает сеть PCN2.




Рис. 2. Нейронная сеть памяти о траекториях движения РТС

На рисунке условно показано M запомненных траекторий, каждая из которых представляет собой цепочку из N элементов нейронной сети T (N индивидуально для каждой траектории).

Под движением по траектории здесь мы понимаем последовательность переходов между возможными согласованными положениями, которые может обеспечивать сеть PCN1. Входами сети управления движением по траектории с низшего уровня являются выходные данные сети PCN2, которые представляют актуальную информацию о согласованном положении исполнительных элементов РТС, где, как говорилось выше, активность каждого нейрона отвечает за одно согласованное положение. С высшего уровня сеть TCN получает информацию о целевой траектории движения. Выходами сети является информация о целевом согласованном положении, которая изменяется в соответствии с обратной связью от PCN2 по текущему положению.

Функциональным элементом сети TCN является кольцевая структура из нескольких нейронов, охваченных положительной обратной связью (рис. 3).




Рис. 3. Кольцевая структура для запоминания точки траектории движения

Каждая такая структура отвечает за одно промежуточное положение системы в движении по траектории. Выход каждой структуры поступает непосредственно на нейрон сети PCN2, активирующий процесс перехода системы в новое целевое положение и одновременно на кольцевую структуру, отвечающую за следующую точку траектории. При этом сигнал подтверждения достижения положения от PCN2 приводит к подавлению генерации импульсов кольцевой структурой и ее отключению, и автоматически активирует следующую кольцевую структуру в цепочке. Особенность связей между двумя соседними структурами заключается в том, что выход нейрона N_2 образует на нейроне N_1 следующего участка как возбуждающие, так и тормозные связи. При этом тормозные связи образуются на соме нейрона и, следовательно, имеют наибольший вес (и наименьшую длительность воздействия), а возбуждающие образуются на длинном дендрите клетки N_1 . Таким образом, активация одной кольцевой структуры не приводит к немедленной активации следующей. Ее активация

становится возможной только после прекращения генерации импульсов нейроном N_2 , когда активность тормозных синапсов на соме нейрона N_1 следующей структуры будет прекращена, а возбуждающий сигнал распространяющийся по дендриту еще не успеет затухнуть.

Экспериментальное исследование

На рис. 4 представлена схема для проведения исследований в среде Matlab.





Рис. 4. Экспериментальная схема с запоминанием трех точек траектории

Здесь в качестве управления с высшего уровня выступает генератор короткой последовательности импульсов, активирующих первую из трех кольцевых структур в цепочке. В качестве имитатора сети PCN выступает набор элементов линии задержки, которые имитируют сигнал подтверждения о достижении положения через одну секунду после получения входного сигнала.

На рис. 5 представлен пример работы описанной сети.



По оси абсцисс – время в секундах,

- 1 – активация процесса воспроизведения траектории (сигнал с высшего уровня),
- 2 – 4 – последовательная активность трех кольцевых структур, соответствующих трем точкам траектории

Рис. 5. Результаты работы

Можно видеть, что однократная активация первой кольцевой структуры приводит к последовательному запуску оставшихся, причем сигналом на запуск

каждого последующего элемента является подтверждение о достижении предыдущего целевого положения.

Заключение

В статье предложена модель рекуррентной нейронной сети на основе модели динамического импульсного нейрона, обеспечивающая воспроизведение движения робототехнической системы по заранее запомненной траектории.

Запуск движения возможен с любой точки траектории, и также в перспективе допускается формирования не только линейной последовательности кольцевых структур, но и их ветвления с возможностью выбора дальнейшей траектории по управляющему сигналу с высшего уровня, а также создания замкнутых последовательностей, для реализации циклических движений.

В дальнейшем предполагается разработка алгоритмов обучения такой сети, которое будет заключаться в формировании новых наборов кольцевых структур, обеспечивающих в дальнейшем воспроизведение определенной траектории движения, и соответствующих связей с низшим уровнем управления.

Список литературы

1. J. L. McKinstry, G. M. Edelman и J. L. Krichmar, A cerebellar model for predictive motor control tested in a brain-based device, т. 103 # 9, PNAS, February 28, 2006, pp. 3387-3392.
2. H. d. Garis, C. Shuo, B. Goertzel и L. Ruiting, A world survey of artificial brain projects, PartI: Large-scale brain simulations, т. 74, Neurocomputing, 2010, pp. 3-29.
3. B. Goertzel, L. Ruiting, I. Arel, H. d. Garis и C. Shuo, A world survey of artificial brain projects, PartII: Biologically inspired cognitive architectures, т. 74, Neurocomputing, 2010, pp. 30-49.
4. А.В. Бахшиев, С.П. Романов. Нейрон с произвольной структурой дендрита, математические модели биологических прототипов // Нейрокомпьютеры: разработка, применение, №3, 2009. – 71-80 с.
5. Бахшиев А.В. Модель нейрона со структурной адаптацией дендритного аппарата для моделирования естественных нейронных сетей управления движением // Нейроинформатика, ее приложения и анализ данных: - материалы XVIII Всеросс. семинара, 27-29 сентября 2013г. / под ред. А.Н. Горбаня, Е.М. Миркеса; ИВМ СО РАН. Отв. за вып. Г.М. Садовская – Красноярск; 2013.– 36-43 с.
6. Ф.В.Гунделах, А.В.Бахшиев. Иерархическая нейронная сеть согласованного управления элементами исполнительной системы робота // Нейроинформатика, ее приложения и анализ данных: - материалы XVIII Всеросс. семинара, 26-28 сентября 2014г. / под ред. А.Н. Горбаня, Е.М. Миркеса; ИВМ СО РАН. Отв. за вып. Г.М. Садовская – Красноярск; 2014.

ОПТИМИЗАЦИЯ РАБОТЫ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ НА ОСНОВЕ ПАРАЛЛЕЛИЗМА

А.Ю. Благодарёв¹, С.А. Субботин², А.А. Олейник³

¹Запорожский национальный технический университет, *alexheus85@gmail.com*

²Запорожский национальный технический университет, *subbotin@zntu.edu.ua*

³Запорожский национальный технический университет, *olejnikaa@gmail.com*

Введение

Для решения задач построения распознающих моделей в различных практических приложениях (в частности, для распознавания речи, изображений, рукописных текстов, обработки данных, и др.) в настоящее время широкое распространение приобретает технология "глубокого обучения" (Deep Learning), представляющая собой разновидность машинного обучения применительно к специальной архитектуре нейронных сетей [1-7].

Центральным понятием методологии глубокого обучения является автоматизированное открытие абстракций, с предположением о том, что более абстрактные представления данных, такие как изображения, видео- и аудиосигналы, как правило, являются более полезными: они представляют собой смысловое содержание данных, в отрыве от низкоуровневых функциональных возможностей из необработанных данных (пикселей, вокселей или волновых форм). Глубокие архитектуры ведут к абстрактным представлениям, поскольку более абстрактные понятия часто могут быть построены посредством менее абстрактных.

Кроме того, в [1–3] установлено, что увеличение масштабов глубокого обучения, т.е. увеличение числа обучающих примеров, параметров модели, или и того и другого одновременно, может значительно улучшить конечную точность классификации. Схема типовой сети глубокого обучения показана на рис. 1.




Рисунок 1 – Схема типовой сети глубокого обучения
(число стрелок пропорционально размеру партий вычислений)

Всё это приводит к значительному увеличению вычислительные затраты на реализацию таких методов, а, следовательно, и к увеличению их времени работы. К традиционным способам решения данной проблемы относят организацию параллельных и распределенных вычислений, в том числе на специализированном аппаратном обеспечении, таком как нейронные чипы, систолические нейропроцессоры, программируемые логические интегральные схемы (ПЛИС / FPGA), распределенные кластерные системы, GRID-технологии, процессоры видеокарт (GPU).

Поскольку при использовании глубокого обучения нейронные сети должны получать и обрабатывать множество данных, используется довольно распространённая в машинном обучении техника, которая заключается в разделении набора данных на небольшие подмножества и обновлении параметров только после того, как был рассчитан градиент из всех образцов в подмножестве. Также применяется разделение общего градиента по числу выборок на партии вычислений (mini-batch), такое разделение даёт возможность проводить вычисления параллельно и независимо друг от друга таким образом, что скорость обучения не зависит от размера такой партии, а сеть может обработать ввод более быстро и точно.

Применение данного подхода объясняется тем, что если обучение начинается с параметров инициализированных случайным образом или даже с предварительно подготовленных параметров, то нет необходимости проходить через все данные, чтобы получить точное обновление градиента, который ведёт в направлении локального минимума. Но если используется слишком большой размер партии вычислений, то захватываются не только общие ошибки, но также ошибки, которые являются трудноуловимыми, кроме того это приводит к увеличению вычислительных затрат. Однако, если экземпляры могут быть изучены параллельно, то большой размер партии вычислений может сократить время обучения.

В то же время, если размер партии вычислений слишком мал, то это приводит к тому, что сеть при обучении не захватит все общие ошибки, которые имеют отношение к набору данных и, таким образом, градиент не сможет привести к оптимуму.

Целью данной работы являлись анализ известных подходов к организации параллелизма вычислений в методах глубокого обучения и разработка рекомендаций по оптимизации работы глубокого обучения на основе параллелизма.

2. Анализ подходов к организации параллелизма

Известны два подхода к организации параллелизма [4]: параллелизм данных (data parallelism) и параллелизм модели (model parallelism).

В параллелизме данных, партии вычислений делятся на несколько GPU, как показано на рис. 2, т.е. каждому GPU даются различные экземпляры данных для обучения, и GPU синхронно обучают одну и ту же модель на своих примерах данных.




Рисунок 2 – Схема сети глубокого обучения, использующей два графических процессора для параллельной обработки данных (каждый GPU вычисляет ошибки и градиенты для половины экземпляров в партии вычислений)

Каждый GPU отвечает за вычисление градиентов в отношении всех параметров модели, но делает это с помощью подмножества выборок в одной конкретной партии вычислений. Это наиболее простой метод распараллеливания, но он требует значительной коммуникации между GPU, поскольку каждый GPU должен передавать как градиенты, так и значения параметров на каждом шагу обновления. Кроме того, каждый GPU требует дополнительной настройки, чтобы параллельная работа всех устройств была эффективной. Имеются сообщения о получении ускорения в 1,5 раза при переходе от одного к двум процессорам в рамках параллелизма данных [5, 6].

Распараллеливание вычислений модели заключается в разделении вычислений отдельной сети между несколькими графическими процессорами, т.е. различные GPU обучают различные слои на одних и тех же примерах данных. [4, 7]. Пример показан на рис. 3.




Рисунок 3 – Схема сети глубокого обучения, использующей два графических процессора для параллелизма модели

В то время как параллелизм модели является более трудно реализуемым, он имеет два потенциальных преимущества по сравнению с параллелизмом данных. Во-первых, он может требовать меньшей пропускной способности канала связи. Во-вторых, это позволяет реализацию моделей, которые являются слишком большими для памяти одного GPU.

Параллелизм данных будет достаточно быстр для небольших сетей и очень медленный для больших сетей, для параллелизма модели всё наоборот. Чем больше параметров в сети, тем более выгодным является параллелизм модели. Его преимущества проявляются при использовании в нейронной сети, где веса не вписываются в единую память GPU.

Тем не менее, при работе с небольшими сетями, где GPU не насыщены и имеют некоторые свободные мощности (не все ядра работают), модель параллелизма будет медленной, в отличие от параллелизма данных. Это происходит потому, что у нас есть только частичная информация для всей партии. С этой частичной информацией, мы не можем вычислить активности в следующем слое и, следовательно, придется ждать завершения синхронизации, чтобы двигаться дальше.

3. Рекомендации по оптимизации глубокого обучения на основе параллелизма

Преимущества производительности при разделении обучения глубокой сети между несколькими машинами, зависит от структуры подключения и вычислительных потребностей модели. Модели с большим количеством параметров или высокими вычислительными требованиями, обычно извлекают пользу от доступа к большему количеству процессоров и памяти, до точки, где доминируют расходы на связь [4].

Ограничением степени ускорения работы параллелизма является разница во времени обработки через различные машины, что приводит к тому, что многие машины ожидают одну наиболее медленную или загруженную машину, чтобы закончить данную фазу вычислений, но, даже не смотря на это, возможность использовать несколько процессоров для обучения одной модели ведёт к значительному сокращению общего времени обучения.

Учитывая выше сказанное, предлагается использовать параллелизм в DBN. В данной архитектуре приоритетом для сокращения времени работы системы является скорость расчетов в RBM, из которых она состоит. Данные расчеты происходят так часто, что любое, даже небольшое сокращение времени, приведёт к значительному увеличению скорости работы сети. Система имеет возможность для параллелизма при одновременном обновлении всех элементов в слое. Параллелизм возможен благодаря структуре RBM и тому факту, что каждый скрытый элемент не зависит от других элементов в слое.

Увеличение производительности сети при использовании параллелизма зависит от множества факторов (применение модели, количество параметров, разделение входных данных между GPU для их наиболее оптимальной загрузки, размер партий вычислений, синхронизация и связь между GPU и др), но при правильной

настройке можно добиться значительного (в несколько раз) увеличения производительности работы сети даже в сравнении с распараллеливанием вычислений между ядрами многоядерных процессоров.

Список литературы

1. Ciresan D. C. Deep big simple neural nets excel on handwritten digit recognition / D. C. Ciresan [et al.] // Neural Computation. – 2010. – Vol. 22. – № 12. – P. 3207-3220.
2. Coates A. An analysis of single-layer networks in unsupervised feature learning / A. Coates, H. Lee, A. Y. Ng. // Artificial Intelligence and Statistics. – 2011. – P. 215-223
3. Le Q.V. On optimization methods for deep learning / Q.V. Le, J. Ngiam, A. Coates [et al.] // 28th International Conference on Machine Learning ICML-2011, Bellevue, 28 June - 2 July 2011 : proceedings. – 2011. – P. 265-272.
4. Dean J. Large scale distributed deep networks / J. Dean, G.S. Corrado, R. Monga [et al.] // Advances in Neural Information Processing Systems 25: 26th Annual Conference on Neural Information Processing Systems, Lake Tahoe, 3-6 December 2012 : proceedings / [ed. by F. Pereira, C.J.C. Burges, L. Bottou, K.Q. Weinberger]. – 2012. – P.1232-1240.
5. Omry Y. Multi-GPU Training of ConvNets [Electronic resource] /Y. Omry. – Access mode: <http://arxiv.org/pdf/1312.5853.pdf>
6. Krizhevsky A. ImageNet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G. Hinton // Advances in Neural Information Processing Systems 25: 26th Annual Conference on Neural Information Processing Systems, Lake Tahoe, 3-6 December 2012 : proceedings / [ed. by F. Pereira, C.J.C. Burges, L. Bottou, K.Q. Weinberger]. – 2012. – P. 1106-1114.
7. Coates A. Deep learning with COTS HPC / A. Coates, B. Huval, T. Wang [et al.] // Journal of Machine Learning Research. – 2013. – Vol. 28. – P. 1337-1345.

ТЕРМОГРАФИЧЕСКИЙ АНАЛИЗ РЕАКЦИИ СИСТЕМЫ САМОРЕГУЛЯЦИИ ОРГАНИЗМА ВДОЛЬ УПРАВЛЯЮЩЕГО ЭНЕРГЕТИЧЕСКОГО МЕРИДИАНА

Н.М. Богатов, А.С. Сеницын

Кубанский государственный университет, *bogatov@phys.kubsu.ru*

Организм человека является открытой энергетической системой, которая откликается на внешние воздействия. Жизнеспособность человека обеспечивают физико-химические процессы саморегуляции, действующие не только на уровне организма, но и на уровне клеток. Интегральная система саморегуляции объединяет ряд подсистем [1], в число которых входит система терморегуляции [2]. Исследование этой системы является актуальной задачей нейробионики и физиологии. Решение этой задачи направлено на построение теплового портрета организма человека и изучение его изменения в различных условиях.

Внутренняя терморегуляция организма реализуется посредством метаболического термогенеза, тока крови, мышечного тонуса кожи, ритма дыхания, частоты сердечных сокращений, выделения пота и контролируется центральной нервной, в частности гипоталамусом, и эндокринной системами. Тепловые и холодовые рецепторы расположены в трех областях тела: в гипоталамусе, грудном отделе спинного мозга и коже [3]. Процессы внутренней терморегуляции и теплообмен с окружающей средой формируют тепловое поле организма. Распределение температуры на поверхности тела определяют тепловизионным методом. Тепловая картина поверхности тела не позволяет однозначно восстановить закономерности внутренних тепловых явлений.

Система терморегуляции включает многократно продублированные элементы, выполняющие функции теплообменников, теплоносителей, источников тепла, датчиков температуры и центров регуляции [2]. Эти элементы объединены цепями управления и обратной связи, взаимодействующими в процессе достижения максимального приспособительного эффекта [1]. Взаимодействие реализуется в различных масштабах посредством макро-, микро- и нанообъектов. Действие системы терморегуляции проявляется в управлении механизмами теплопередачи на макроуровне органов и частей тела, микроуровне кровеносных сосудов и клеток окружающей их ткани, наноуровне мембран нервных окончаний терморецепторов и молекул белков [3 – 6].

Полученные в [7, 8] результаты демонстрируют возможность исследовать тепловизионным методом напряжение функциональных подсистем системы терморегуляции организма, в частности визуализировать реакцию подкожной сосудистой сети без введения в кровь инородных веществ, как это предлагалось в работах [9, 10], а за счет локальных изменений температуры поверхности участков кожи.

Симпатическая часть вегетативной нервной системы участвует в формировании как температуры, так и электропроводности кожи. Изменение состояния внутренних органов отражается на электрических характеристиках кожи вследствие висцерокожного симпатического рефлекса [11]. Существует корреляция между

изменением электропроводности в репрезентативных акупунктурных точках и состоянием энергетических меридианов, отражающих функциональное состояние соответствующих им внутренних органов и систем организма. Следовательно, изменение температуры вдоль энергетических меридианов также отражает внутренние процессы организма.

Цель работы – тепловизионное исследование реакции системы терморегуляции, стимулированное массажем воротниковой зоны.

Термограммы регистрировались с помощью тепловизора testo 885-2, имеющего матричный детектор 320×240 пикселей, температурную чувствительность $< 0,03$ К. Исследования проводились в закрытом помещении при температуре 22 °С, влияние посторонних источников тепла исключалось. Повышение разрешающей способности термограмм достигнуто с помощью псевдоцветовой палитры компьютерной программы [12].

На рис.1А, рис.1Б, рис.1С представлены термограммы, соответственно, до массажа воротниковой зоны, сразу после массажа, через 10 минут пребывания в спокойном состоянии. Линия вдоль позвоночника на каждой термограмме проходит вдоль управляющего меридиана GV (задний срединный меридиан).




Рис.1. Термограммы: А – до массажа; Б – сразу после массажа; С – через 10 минут после массажа; 1 – псевдоцветовая шкала температуры для термограмм А, Б; 2 – псевдоцветовая шкала температуры для термограммы С

На рис.2 показано изменение радиационной температуры $T(L)$ вдоль линий на термограммах рис.1А, рис.1Б, рис.1С в направлении снизу вверх. Расстояние L вдоль каждой линии измеряется в безразмерных единицах (пикселях).




Рис.2. Изменение температуры вдоль управляющего меридиана GV:
1 - термограмма рис.1А, 2 – термограмма рис.1Б, 3 – термограмма рис.1С

Тепловое поле на термограмме рис.1А асимметрично относительно меридиана GV. Коэффициент корреляции для прямоугольных областей, расположенных симметрично слева и справа от меридиана GV, $k_1 = 0.95$. Средняя температура в грудном отделе справа от меридиана GV выше, чем слева на $\Delta T_{\text{ср}} = 0,1$ °C, что свидетельствует о функциональной перегрузке верхнегрудных позвоночно двигательных сегментов справа.

Сравнение рис.1А и рис.1Б показывает, что в результате массажа воротниковой зоны распределение теплового поля стало более симметричным по всей поверхности спины. Коэффициент корреляции для прямоугольных областей на рис.1Б, расположенных симметрично слева и справа от меридиана GV, $k_2 = 0.98$. Средняя температура в грудном отделе справа и слева от меридиана GV совпадает. Повышение коэффициента корреляции и выравнивание средней температуры в грудном отделе справа и слева от меридиана GV свидетельствуют о снятии функциональной перегрузки верхнегрудных позвоночно двигательных сегментов справа.

Распределение теплового поля в пояснично-крестцовом отделе на термограмме рис.1А слева и справа асимметрично, что свидетельствует о функциональной перегрузке позвоночно-двигательных сегментов на уровне L2-L3 справа. Симметрия восстанавливается после массажа воротниковой зоны (рис.1Б), следовательно, функциональная перегрузка справа в пояснично-крестцовом отделе снимается.

Согласно восточной рефлексотерапии, задний срединный меридиан начинается в конце копчика, проходит по позвоночнику, затылку, вдоль лба, носа и заканчивается в середине верхней губы, энергетический поток направлен снизу вверх. Он, как и

передний срединный меридиан, управляет либо дыхательной, либо пищеварительной, либо мочеполовой функцией в зависимости от уровня туловища, на котором его рассматривают. Задний срединный меридиан («сосуд-управитель») объединяет все ЯН-меридианы [13].

Управляющий меридиан GV связан с физиологией мозга, позвоночника и половых органов, поэтому изменение температуры, представленное на рис.2, вдоль линий на термограммах рис.1 является косвенной характеристикой энергетических процессов в этих органах.

Увеличение температуры сразу после массажа в области воротниковой зоны $L > 120$ (зависимость 2 на рис.2) в сравнении с исходными значениями (зависимость 1 на рис.2) является закономерным результатом активизации кровообращения.

Поясничная область массажем не затрагивалась, однако температура в ней при $L < 80$ выше (зависимость 2 на рис.2), чем до массажа (зависимость 1 на рис.2). Этот эффект обусловлен васкуляризацией, стимулированной массажем воротниковой зоны, богатой кровеносными сосудами. В результате усилилось обеспечение кровью других органов, областей и частей тела, что проявляется в увеличении потока энергии вдоль управляющего меридиана.

Температура вдоль всего позвоночника через 10 мин. после массажа, представленная зависимостью 3 на рис.2, больше, чем на зависимостях 1 и 2 рис.2. Следовательно в течение 10 мин. активизация энергообмена вдоль меридиана GV сохраняется. Это сопровождается выравниванием значений температуры по всей спине (рис.1С). Значения стандартного отклонения для распределения температуры слева и справа от меридиана GV близки и меньше, чем для термограмм на рис.1А, рис.1Б, что свидетельствует об активизации процессов теплопередачи и повышении тонуса кровеносных сосудов.

Таким образом, эффект воздействия на воротниковую зону проявляется в усилении энергообмена вдоль управляющего меридиана GV. Процесс повышения температуры не ограничен временем непосредственного воздействия, что есть следствие активизации системы саморегуляции организма. Васкуляризация в воротниковой зоне открыла каналы обмена между органами-производителями и органами-накопителями энергии.

Рассмотренные явления проявились в восстановлении симметрии термограмм, выравнивании распределения температуры и её повышении вдоль управляющего меридиана GV и всей спины.

Список литературы

1. Анохин П.К. Очерки по физиологии функциональных систем / П.К.Анохин. — М.: Медицина, 1975. — 448 с.

2. Ермакова И.И. Математическое моделирование процессов терморегуляции у человека / И.И.Ермакова. — Итоги науки и техники. ВИНТИ, Физиология человека и животных, 1987, Т. 33. — 136 с.
3. Иванов К.П. Основы энергетики организма: Теоретические и практические аспекты. Т. 1. Общая энергетика, теплообмен и терморегуляция / К.П.Иванов. — Л.: Наука, 1990. — 307 с.
4. Физиология кровообращения: Физиология сосудистой системы. Руководство по физиологии / Под ред. Б.И.Ткаченко. — Л.: Наука, 1984. — 652 с.
5. Парашин В.Б. Биомеханика кровообращения / В. Б.Парашин, Г. П.Иткин. — М.: МГТУ им. Н.Э. Баумана, 2005. — 224 с.
6. Бегун П.И. Биомеханика / П.И.Бегун, Ю.А.Шукейло. — СПб.: Политехника, 2000. — 463 с.
7. Богатов Н.М. Анализ теплопереноса в слое биологической ткани с распределенной системой кровеносных сосудов / Н.М.Богатов, О.Н.Пелипенко // Российский физиологический журнал. — 2005. — Т.91. — № 9. — С.1033 – 1042.
8. Андросова Т.В. Тепловизионные исследования реакций терморегуляторной системы организма / Т.В.Андросова, Н.М.Богатов, Л.Р.Григорьян и др. // В: Современные проблемы физики, биофизики и информационных технологий. — Краснодар: Краснодарский ЦНТИ. — 2010. — С.7 – 22.
9. Иваницкий Г.Р. Возможности термографии в современной медицине: исследование пространственного изменения температуры кожи человека при введении перфторана / Г.Р.Иваницкий, А.А.Деев, Е.И.Маевский и др. // Доклады академии наук. Физиология. — 2003. — Т.393. — №3. — С.419–423.
10. Иваницкий Г.Р. Особенности теплового проявления подкожных источников нагрева на поверхности тела человека / Г.Р.Иваницкий, А.А.Деев, Т.Н.Пашовкин и др. // Доклады академии наук. Биохимия, биофизика, молекулярная биология. — 2008. — Т.420. — №4. — С. 551–555.
11. Электропунктурная диагностика по методу И. Накатани. Министерство здравоохранения РФ. Методические рекомендации № 2002/34 / Н.А.Гаврилова, С.В.Коновалов, К.А.Резаев и др. — МЗ РФ: Москва, 2002. — 24 с.
12. Богатов Н.М. Программа спектрального анализа термограмм / Н.М.Богатов, Л.Р.Григорьян // Федеральная служба по интеллектуальной собственности, патентам и товарным знакам РФ. Свидетельство об официальной регистрации программы для ЭВМ №2006612378. Зарегистрировано: 6.07.2006 г.
13. Гаваа Лувсан. Очерки методов восточной рефлексотерапии / Лувсан Гаваа. — Новосибирск: Наука (сибирское отделение), 1980. — 279 с.

МЕТОД СНИЖЕНИЯ ГОСПИТАЛЬНОЙ ЛЕТАЛЬНОСТИ У ПАЦИЕНТОВ С ОСТРЫМ ИНФАРКТМ МИОКАРДА

С.Е.Головенкин¹, И.С.Масич², Д.А.Россиев¹, О.Г. Овечкин³, Г.В.Матюшин¹,
Е.Ю.Пелипецкая¹

¹Красноярский Государственный медицинский университет,
кафедра внутренних болезней № 1, gse2008@mail.ru

²Сибирский Государственный аэрокосмический университет,

³Военный госпиталь в/ч 52630, г.Чита

Введение

Большое количество задач распознавания, привлекающих внимание исследователей как в медицине, так и во множестве других областей, может быть сформулировано следующим образом. Имеется выборка данных, которая состоит из двух непересекающихся множеств Ω^+ и Ω^- n -мерных векторов. Каждый вектор соответствует некоторому пациенту, векторы множества Ω^+ соответствуют пациентам, находящимся в некотором медицинском состоянии (например, болен или имеет осложнение заболевания), а векторы Ω^- не соответствуют этому состоянию. Компоненты векторов (называемые признаками, переменными, характеристиками или атрибутами) представляют собой результаты определенных измерений, тестов или просто показывают присутствие или отсутствие определенных симптомов. Эти компоненты могут быть численными, номинальными или бинарными.

Задача состоит в том, чтобы на основании имеющейся выборки данных (классифицированных ранее наблюдений) извлечь информацию о состоянии «нового» пациента, наблюдение которого не содержится в выборке. Главная цель решения таких задач – на основе анализа данных и вычислительных систем диагностики и прогнозирования определить индивидуальную терапию для пациента.

Для решения этой задачи исследуется метод анализа данных, в основе которого лежит принцип вывода логических закономерностей или правил. Каждое правило должно покрывать достаточно много объектов одного класса и практически не покрывать объекты другого класса. Взяв вместе некоторое количество правил, можно получить алгоритм (модель, решающее правило), который будет решать поставленную задачу классификации.

Построение эффективных правил и модели классификации является сложной комбинаторной задачей. Результаты ее решения определяются видом сформированных критериев и ограничений, а также используемыми алгоритмами оптимизации.

Главной особенностью использования такого подхода является то, что в результате работы метода из базы данных извлекаются правила, с помощью которых

можно классифицировать объекты и без помощи компьютера и вычислительной системы.

1. Осложнения инфаркта миокарда

Инфаркт миокарда - распространенное и грозное заболевание. Бурное распространение этого заболевания за последние полвека сделало его одной из наиболее острых проблем современной медицины. Несмотря на то, что внедрение современных лечебно-профилактических мероприятий несколько снизило смертность от инфарктов, она продолжает оставаться довольно высокой. Течение заболевания у пациентов с ИМ различно. ИМ может протекать без осложнений или с осложнениями, не ухудшающими долгосрочный прогноз. В то же время, около половины пациентов в острый и подострый периоды имеют осложнения, приводящие к ухудшению течения заболевания и даже летальному исходу. Предвидеть развитие этих осложнений не всегда может даже опытный специалист. В связи с этим, прогнозирование осложнений ИМ с целью своевременного проведения необходимых профилактических мероприятий представляется актуальной задачей.

2. Логический анализ данных

В основе предлагаемого подхода к классификации данных лежит метод, происходящий из теории комбинаторной оптимизации и называемый логическим анализом данных (Logical Analysis of Data – LAD). Этот метод успешно использовался для решения ряда задач из различных областей. Основная идея метода заключается в совместном использовании действий по «дифференцированию» и «интегрированию», производимых на области пространства исходных признаков, содержащей заданные *позитивные* и *негативные* наблюдения. На шаге «дифференцирования» определяется семейство малых подмножеств, обладающих характерными позитивными и негативными чертами. На шаге «интегрирования» формируемые определенным образом объединения этих подмножеств рассматриваются как аппроксимации областей пространства признаков, содержащих позитивные и, соответственно, негативные наблюдения.

Ниже приведены последовательные элементы метода:

а) Для исключения избыточных переменных в исходной выборке данных в множестве переменных определяется некоторое подмножество S , используя которое можно различать позитивные наблюдения от негативных. Далее для работы метода используются проекции Ω_S^+ и Ω_S^- множеств Ω^+ и Ω^- на S . Такая процедура используется во многих методах классификации и анализа данных. Особенностью осуществления ее в LAD является то, что происходит выделение не только значимых по отдельности признаков, но и определение комбинаций признаков, которые оказывают коллективное влияние на результат.

б) Множество Ω_S^+ покрывается семейством однотипных подмножеств уменьшенного пространства, каждое из которых имеет значительное пересечение с

Ω_S^+ , но не пересекается с Ω_S^- . Такие подмножества называются «позитивными паттернами». Аналогично множество Ω_S^- покрывается «негативными паттернами».

в) Определяется подмножество позитивных паттернов, объединение которых покрывает все наблюдения Ω_S^+ , и подмножество негативных паттернов, объединение которых покрывает все наблюдения Ω_S^- . Совокупность этих двух подмножеств называется «моделью».

г) Позитивный или негативный характер некоторого наблюдения, покрываемого объединением двух подмножеств модели, определяется с помощью решающего правила, основанного на этих подмножествах.

Отличительной особенностью предлагаемого метода является то, что вместо того, чтобы просто ответить на вопрос, к какому из классов принадлежит новое наблюдение, он строит аппроксимацию областей пространства признаков, содержащей наблюдения соответствующих классов. Наиболее важные преимущества такого подхода – это возможность дать объяснение для любого решения, полученного методом, возможность выявления новых классов наблюдений, возможность анализа роли и природы признаков.

3. Бинаризация

Рассматриваемый метод предназначен для работы с выборками данных, в которых признаки принимают бинарные значения. Так как исходная выборка может состоять из метрических переменных, необходимо воспользоваться *методом бинаризации*. Существует несколько способов кодирования.

Один из простейших способов бинаризации состоит в следующем. Каждой метрической переменной ставится в соответствие несколько бинарных переменных. Бинарная переменная принимает значение 1, если значение соответствующей метрической переменной принимает значение выше определенного порога, и наоборот. Такой способ называется «единичным». Его недостатком является то, что существует большое число комбинаций бинарных переменных, которым не соответствуют точки в исходном пространстве ($2^n - n - 1$). Этот недостаток затрудняет использование такого способа для кодирования переменных критериальной функции при решении задач оптимизации, так как большое число решений будут недопустимыми. Но в данном случае, для классификации, это не имеет значения, так как бинарные переменные получаются путем кодирования заданных метрических переменных. Основным же преимуществом такого способа является соответствие расстояний в исходном и бинарном пространствах. Это значит, что точки, близкие в исходном пространстве, являются близкими и в бинаризованном. А это, в свою очередь, позволяет еще в процессе бинаризации минимизировать число порогов (и, соответственно число бинарных переменных), ставя в соответствие близким значениям исходной переменной

одно и то же значение в бинарном пространстве (при условии, что позитивные и негативные множества наблюдений останутся непересекающимися).

4. Модель классификации

4.1. Поиск паттернов

В основе рассматриваемого подхода лежит понятие паттерна. *Позитивным паттерном* называется подкуб пространства булевых переменных B_2^t , который пересекается с множеством Ω_S^+ и не имеет общих элементов с множеством Ω_S^- . Негативный паттерн задается аналогично.

Позитивный ω -паттерн для $\omega \in \{0,1\}^t$ - это паттерн, содержащий в себе точку ω . Для каждой точки $\omega \in \Omega_S^+$ найдем *максимальный ω -паттерн*, то есть покрывающий наибольшее число точек Ω_S^+ .

Соответствующий подкуб зададим с помощью переменных y_j :

$$y_j = \begin{cases} 1, & \text{если } x_i \text{ зафиксирована в подкубе,} \\ 0, & \text{в противном случае.} \end{cases}$$

То есть путем фиксирования l переменных исходного куба размерностью t получаем подкуб размерностью $(t-l)$ и с числом точек 2^{t-l} .

Условие, говорящее о том, что позитивный паттерн не должен содержать ни одной точки Ω_S^- , требует, чтобы для каждого наблюдения $\rho \in \Omega_S^-$ переменная y_j принимала значение 1 по меньшей мере для одного j , для которых $\rho_j \neq \omega_j$:

$$\sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq 1 \text{ для любого } \rho \in \Omega_S^-.$$

Усиление ограничения для повышения устойчивости к ошибкам производится путем замены числа 1 в правой части неравенства на целое положительное число d .

С другой стороны, позитивное наблюдение $\sigma \in \Omega_S^+$ будет тогда входить в рассматриваемый подкуб, когда переменная y_j принимает значение 0 для всех индексов j , для которых $\sigma_j \neq \omega_j$. Таким образом, число позитивных наблюдений, покрываемых ω -паттерном, может быть вычислено как

$$\sum_{\sigma \in \Omega_S^+} \prod_{\substack{j=1 \\ \sigma_j \neq \omega_j}}^t (1 - y_j).$$

Таким образом, имеем задачу условной псевдобулевой оптимизации с алгоритмически заданными функциями

$$\sum_{\sigma \in \Omega_S^+} \prod_{\substack{j=1 \\ \sigma_j \neq \omega_j}}^t (1 - y_j) \rightarrow \max, \quad (1)$$

$$\sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq d \text{ для любого } \rho \in \Omega_S^-, y \in \{0,1\}^t. \quad (2)$$

Целевая функция задачи является унимодальной монотонной псевдобулевой функцией, т.е. имеет единственный безусловный максимум, находящийся в точке $y^0 = (0,0,\dots,0)$, и убывает при удалении от точки максимума (при смене любой компоненты с 0 на 1). Причем функция эта задана алгоритмически, так как для ее вычисления необходимо перебрать все наблюдения выборки Ω_S^+ . Функция ограничения является также унимодальной и монотонной псевдобулевой функцией, заданной алгоритмически.

Аналогично формулируется задача нахождения максимальных отрицательных паттернов.

4.2. Решающее правило

В итоге получаем семейство максимальных паттернов, число которых ограничено мощностью выборки данных $|\Omega^+ \cup \Omega^-|$. Обозначим $M_1^+, \dots, M_p^+$ и $M_1^-, \dots, M_q^-$ соответственно множества позитивных и негативных паттернов.

Чтобы классифицировать новое наблюдение, воспользуемся следующим решающим правилом:

- 1) Если наблюдение удовлетворяет условиям одного или нескольких позитивных паттернов и не удовлетворяет условиям ни одного из негативных, то оно классифицируется как позитивное.
- 2) Если наблюдение удовлетворяет условиям одного или нескольких негативных паттернов и не удовлетворяет условиям ни одного из позитивных, то оно классифицируется как негативное.
- 3) Если наблюдение удовлетворяет условиям p' из p позитивных паттернов и q' из q негативных, то «знак» наблюдения определяется как $p'/p - q'/q$.
- 4) В случае, если наблюдение не удовлетворяет условиям ни одного паттерна, позитивного или негативного, то оно остается неклассифицированным.

В случае большого объема выборки данных число различных паттернов может быть велико, и решается задача определения *модели*, состоящей из некоторого числа паттернов, так, чтобы она была способна классифицировать те же наблюдения, которые можно классифицировать с помощью полной системы паттернов.

4.3. Устойчивость к выбросам

Найденный паттерн характеризуется *покрытием* – числом объектов определенного класса, которые он захватывает, и *степенью* – количеством фиксированных переменных, которые определяют этот паттерн. Согласно приведенной выше оптимизационной модели (1)-(2) паттерн не покрывает ни одного объекта другого класса (из обучающей выборки).

Наибольшую ценность представляют паттерны, которые имеют наибольшее покрытие. Чем больше покрытие, тем лучше паттерн отображает образ класса.

Степень паттерна обычно не должна быть слишком большой. Как видно из модели: при уменьшении степени происходит увеличение покрытия, но уменьшать степень можно лишь до тех пор, пока не происходит захвата ни одного объекта другого класса.

Специфика описанной выше задачи прогнозирования состоит в том, что база данных имеет большое число неизмеренных значений (пропущенных данных), а сделанные измерения могут быть неточны либо ошибочны. Шумы и выбросы приводят к тому, что объекты различных классов «накладываются» друг на друга, попадая в «область» противоположного класса. В результате вычисляемые паттерны получаются с большей степенью и с существенно меньшим покрытием, чем если бы выбросов и неточностей не было, а итоговая модель состоит из большого числа маленьких паттернов (с малым покрытием). Это не позволяет построить эффективную модель классификации с «хорошо интерпретируемыми» правилами (в которых участвует небольшое число признаков) и с высокой точностью распознавания.

Для повышения устойчивости метода к выбросам следует ослабить ограничение (2) – сделать возможным, чтобы паттерн захватывал некоторое малое число объектов другого класса. Тогда степень вычисляемых паттернов уменьшится, а покрытие увеличится.

Ограничение оптимизационной модели будет выглядеть следующим образом.

$$\sum_{\rho \in \Omega_S} z_{\rho} \leq D, \text{ где } z_{\rho} = \begin{cases} 0, & \text{если } \sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq d, \\ 1, & \text{в противном случае;} \end{cases} \quad (3)$$

где D – число объектов другого класса, которые допускаются быть покрытыми паттерном (целое неотрицательное число).

Функции (1)-(3) построенной модели оптимизации задаются алгоритмически, т.е. вычисляются через определенную последовательность операций. Для решения задачи оптимизации использовались алгоритмы оптимизации, основанные на поиске граничных точек допустимой области. Эти алгоритмы были разработаны специально для этого класса задач и основаны на поведении монотонных функций модели оптимизации в пространстве булевых переменных. Алгоритмы поиска граничных точек

являются поисковыми, т.е. не требуют задания функций в явном виде, с помощью алгебраических выражений, а используют вычисления функций в точках.

5. Результаты

Результаты сравнительных испытаний метода рассмотрим на примере прогнозирования осложнения инфаркта миокарда – фибрилляции предсердий.

Для проведения испытаний использовалась выборка данных, состоящая из 164 пациентов с осложнением (позитивные объекты) и 193 объектов без указанного осложнения (негативные объекты). Десятая часть из них (16 и 20 пациентов соответственно) использовалась для контроля и в построении решающей модели не участвовала.

В результате бинаризации из 113 признаков различного типа (бинарных, номинальных, численных) было получено 207 бинарных признаков.

В таблице 1 представлены результаты испытаний с использованием двух оптимизационных моделей: с ограничением (2), исключающим захват паттерном объекта другого класса, и с ограничением (3), позволяющим покрытие паттерном нескольких объектов ($D=10$) другого класса. В таблице приведены средние значения покрытий и степени для набора паттернов.

Таблица 1

Задача оптимизации	Множество паттернов	Покрытие негативных объектов	Покрытие позитивных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	негативные паттерны	12	0	6	55
	позитивные паттерны	0	9	6	69
Целевая функция (1), ограничение (3)	негативные паттерны	35	10	6	60
	позитивные паттерны	10	25	6	88

Точность классификации определяется двумя значениями: чувствительностью – точностью определения пациентов с осложнением, и специфичностью – точностью определения пациентов без осложнений. На практике к чувствительности предъявляются большие требования, чем к специфичности; полученные результаты классификации в должной мере соответствуют этому.

Если необходимо, чувствительность можно повысить за счет специфичности. Для этого нужно внести веса в решающее правило (которое описано выше): $\alpha \cdot p'/p - \beta \cdot q'/q$.

Примеры правил, из которых строится решающая модель, приведены в таблице 2 (примечание: в таблице приведены лишь некоторые признаки – те, которые используются в этих правилах).

Таблица 2

паттерны	Признаки											
	AGE	SEX	STEN OK_ AN	DLIT _AG	S_AD _ORIT	ANT _IM	INF _IM	N_R _ECG _P	N_R _ECG _P_4	ROE	TIME _B_S	NOT _NA _2_N
негативные				≥ 4	≥ 140		≥ 1					
	<75	1				<1	≥ 1		0			
				<6				0	0	<13		
	<75		≥ 2							≥ 22		
		1					<3	0				
позитивные			≥ 3								≥ 3	<1
				≥ 4	≥ 110		<1					
			≥ 3			≥ 3	<3					
	≥ 62				<160		<1				<5	
				≥ 6			<1					<1

Заключение

Таким образом, модификация условий при поиске правил позволяет находить паттерны с более высоким покрытием, из которых строится более точная модель распознавания. Применение такого подхода необходимо при решении задач с наличием выбросов и шумов и с большим количеством пропусков в выборке данных.

Задача прогнозирования осложнений инфаркта миокарда решена с точностью, сопоставимой с точностью решения посредством искусственных нейронных сетей. При этом логический анализ данных дает ряд преимуществ при практическом использовании. Прежде всего, в явном виде известны правила, по которым принимается решение о принадлежности к какому-либо классу. Кроме того, при применении модели классификации к новому пациенту по тому, каким числом паттернов покрываются его данные, можно судить о вероятности возможной ошибки при распознавании.

РАЗРАБОТКА ПАРАЛЛЕЛЬНЫХ ПРОГРАММ ЭВОЛЮЦИОННЫМИ МЕТОДАМИ

Е.А. Кольчугина

Пензенский государственный университет,
кафедра «Математическое обеспечение и применение ЭВМ», *kea_sci@list.ru*

Разработка современного программного обеспечения представляет собой сложный технологический процесс, обладающий рядом особенностей, затрудняющих реализацию качественных программных продуктов. В первую очередь среди таких особенностей необходимо отметить:

- катастрофически быстро возрастающий объем программного кода, необходимого для реализации функциональных возможностей современных программ;
- выполнение разработки коллективом (зачастую большим) программистов и специалистов смежных областей (например, дизайнеров), которые могут покидать коллектив или присоединяться к нему на разных стадиях осуществления проекта.

Если речь идет о сложном современном программном проекте, то реальностью становятся ситуации, когда объем разработки столь велик, что она не может полностью быть охвачена умом и памятью одного человека. Таким образом, проект необходимо должен быть разделен на отдельные части, и при его выполнении неизбежно возникнут специфические ошибки, связанные с нестыковками и противоречиями между отдельными частями проекта.

Еще одной причиной возникновения подобных ошибок является непрерывное изменение состава команды специалистов, работающих над проектом: специалисты, хорошо владеющие тематикой проекта и знающие его детальные особенности, могут покидать его в связи со сменой места работы или переходом к работе над другим проектом. Вновь прибывающие на их места специалисты нуждаются в длительном периоде времени для освоения требований и особенностей реализации проекта, а также для адаптации к коллективу.

Помимо фактора возрастания сложности программных проектов и влияния человеческого фактора, на качество разработки оказывают влияние требования, предъявляемые к большинству современных программ. Одним из таких требований, выходящих в последнее время едва ли не на первое место, является пространственная распределенность. Распределенность понимается как в смысле пространственной распределенности данных, обрабатываемых программой, так и в смысле распределенности выполняемых вычислений и особенностей среды, в которой функционирует программа. Выполнение требований обеспечить распределенность как вычислений, так и данных также вносит свой вклад в возрастание сложности программного обеспечения.

Хотя все более широкое распространение получают использование принципов виртуализации и применение промежуточного программного обеспечения (middleware), скрывающего особенности реально используемой аппаратно-программной платформы, тем не менее, необходимо учитывать тот факт, что в

большинстве своем современное программное обеспечение функционирует в многопользовательской многозадачной среде.

Особенностью таких сред является необходимость совместного использования общих ресурсов: аппаратных, программных и информационных. Разделение ресурсов требует обеспечения отсутствия конфликтов. Наиболее драматичны конфликты по использованию программных ресурсов. Так, например, обновление программного компонента, выполненное одним из выполняющихся в многозадачной среде приложений, может вывести из строя все остальные приложения, несовместимые с обновленной версией компонента.

Все вышесказанное позволяет сделать о том, что разработка программного обеспечения на сегодняшний день представляет собой сложный, зачастую трудно управляемый процесс, и трудности эти будут со временем только возрастать. Также будет увеличиваться сложность решения задач системного администрирования как обеспечения управления уже функционирующими приложениями в составе распределенных многопользовательских и многозадачных сред.

В связи с этим, было бы желательно, чтобы программное обеспечение обладало возможностями адаптации к среде выполнения, самооптимизации и возможно, самопрограммированию. Подобные возможности могут быть следствием применения методов теории искусственного интеллекта, подразумевающих накопление и обработку знаний. В частности, в мультиагентных системах применение рассуждений на знаниях, выполняемых отдельными агентами, или наличие у агентов искусственных нейронных сетей, позволяет обеспечить постепенную интеллектуализацию программной системы в целом [1].

Однако нельзя не отметить, что методы теории искусственного интеллекта довольно сложны, и соответственно, усложняют программное обеспечение, работу которого они призваны оптимизировать. Более привлекательным представляется применение биоинспирированных вычислений, вполне согласующихся с концепцией вездесущих вычислений (*ubiquitous computing*) [2]. Биологические и биохимические процессы, происходящие повсеместно в живой природе, можно рассматривать как аналоги вычислений, которым имманентно присущи массовость и параллелизм.

К моделям биоинспирированных вычислений можно причислить генетические алгоритмы и эволюционные вычисления [3], генетическое программирование [4], а также модели теории искусственной жизни [5]. Эти модели имитируют процессы, происходящие в биологических системах, и исходят из дарвиновской концепции эволюции, подразумевающей борьбу за существование и естественный отбор.

Генетические алгоритмы и эволюционные вычисления имитируют процессы размножения и передачи наследственной информации между членами популяции, представляющими возможные решения исходной задачи. Решения определенным образом кодируются, как правило, с помощью битовых последовательностей. Каждое решение рассматривается как пространственная координата некоторого многомерного пространства. Этой координате сопоставляется значение некоторой функции, характеризующей приспособленность особи, то есть оптимальность решения. Таким

образом, процесс решения задачи с помощью генетических алгоритмов сводится к перемещению по заданному ландшафту приспособленности.

Концепция генетического программирования сходна с генетическими алгоритмами. Здесь также производится поиск решения, наилучшим образом отвечающего поставленной задаче, то есть наилучшим образом к ней приспособленного. Однако, в отличие от генетических алгоритмов, решение представляет собой не данные, а программу. Поскольку большинство простейших вычислительных операций являются бинарными, программы задаются в виде бинарных древовидных структур. Над этими структурами могут быть выполнены операции, сходные с операциями генетических алгоритмов. Трудность применения генетического программирования связана с обеспечением сохранения семантики программ при выполнении операций над деревьями. Традиционными сферами приложения генетического программирования являются программы на языках обработки списков. Однако принципы, сходные с принципами генетического программирования, могут быть применены для генерации HTML-документов [6].

Модели искусственной жизни предназначены для воспроизведения в небиологической среде принципов, присущих динамике биологических систем [5]. Спектр этих моделей обширен и включает в себя модели, реализуемые как аппаратно, так и программно, а также так называемые «влажные» вычисления [7].

В основу моделей искусственной жизни также положены принципы, присущие дарвиновской теории эволюции (иногда – с элементами ламаркианства и имитацией эффекта Болдуина [8]).

Среди моделей искусственной жизни есть группа моделей, непосредственно имеющих дело с эволюционной саморазработкой программ. Это модели эволюционирующих ассемблерных программ и их сообществ. Каждая такая программа может рассматриваться как модельный аналог молекулярного организма, существовавшего на ранних стадиях развития живого вещества. Наиболее известными представителями этой группы моделей являются модели «Tierra»[9] и «Avida»[10].

На примере этих моделей показано, что программы, написанные на специальной упрощенной версии ассемблера и обладающие возможностью самокопирования в пределах замкнутого модельного пространства, могут эволюционировать, разбиваться со временем на виды и развивать сложные формы отношений, такие как аналог полового размножения, отношения типа «паразит-хозяин» или даже некоторые формы кооперации. Однако такие программы не обладают выраженной практической полезностью. Чтобы получить сколько-нибудь полезную с точки зрения практического применения программу, придется затратить огромное количество процессорного времени. Основная проблема, присущая разработке программ с помощью средств, сходных с «Tierra» и «Avida», это хрупкость кода. Аналогии операций генетических алгоритмов, выполняемые над эволюционирующими ассемблерными программами, или цифровыми организмами, способны разрушить семантически целостные фрагменты кода.

С целью обеспечить возможность создания программных систем, способных к самооптимизации и саморазвитию путем самоорганизации, автором в [11] была предложена парадигма программирования, основанная на аналогии с термодинамическими процессами, происходящими в системах связанных между собой химических реакций. Если рассматривать процессорное время как аналог свободной энергии, а программы как аналоги групп взаимосвязанных реакций, то большинство программ стремится к расходованию доступного процессорного времени без его возобновления, то есть к аналогу равновесия. Напротив, самоорганизующиеся программные единицы, функциональная модель которых приведена в [11], стремятся «заработать» дополнительные единицы процессорного времени, то есть совершают работу против равновесия, увеличивая доступный аналог процессорного времени.

В моделях «Tierra» и «Avida» цифровые организмы также стремятся увеличить запас внутренней энергии. Однако в предложенной автором модели эволюционирующие программы имеют более сложную структуру, фенотип и генотип цифрового организма в предложенной автором модели разделены между собой. Фенотип задает программный код и данные программы, а генотип кодирует их в виде последовательности неотрицательных целых чисел. Благодаря этому удастся сохранить смысловую ценность программы, так как преобразованиям подвергается генотип, а генам соответствуют не отдельные команды, а их блоки. Таким образом, изменяться может реализация функции, но не сама функция.

Разделение генотипа и фенотипа позволяет решать задачи построения параллельных версий программ. Числовую последовательность, задающую генотип, можно рассматривать как модель последовательного алгоритма. Тогда моделью множества параллельных алгоритмов может служить матрица, полученная путем сгибания и укладки последовательности. Конкретный экземпляр алгоритма может быть получен путем построения рекурсивного разбиения матрицы на систему подмножеств.

Таким образом, построение параллельных версий алгоритмов может быть автоматизировано. Естественным критерием приспособленности здесь выступает запас единиц доступного процессорного времени, который будет возрастать у программ с наилучшей адаптацией к среде выполнения.

Необходимо отметить, что концепции и методы эволюционной разработки программ получают все большее распространение. Еще одной концепцией программирования, которую можно причислить к биоинспирированным вычислениям, является концепция искусственных иммунных систем [13,14]. Эта концепция также предполагает саморазработку программ в результате их взаимодействия друг с другом. Однако по сравнению с ранее рассмотренными, концепция существенно усложняется из-за необходимости введения множества дополнительных служебных элементов.

В заключение необходимо отметить, что методы эволюционной разработки программ, основанные на самоорганизации и самопрограммировании, несомненно, будут развиваться и постепенно войдут в повседневную практику.

Список литературы

1. Рассел С., Норвиг П. Искусственный интеллект: современный подход, 2-е изд.: Пер. с англ. — М.: Издательский дом “Вильямс”, 2006. — 1408 с.
2. Mitchell M. Ubiquity symposium: Biological Computation// Ubiquity.—v.2011 (No.February), 2011.—Pp. 1-7.
3. Holland J.H. Building Blocks, Cohort Genetic Algorithms, and Hyperplane-Defined Functions// Evolutionary Computations.— Vol. 8(4).— Massachusetts Institute of Technology, MIT Press, 2000.—P. 373-391.
4. Koza J. R., Bennett F. H, Andre D., Keane M. A. Genetic Programming: Biologically Inspired Computation that Creatively Solves Non-Trivial Problems// Evolution as Computation/ DIMACS Workshop, Princeton, January 1999.— Berlin Heidelberg: Springer-Verlag Berlin Heidelberg, 2002. —Pp. 95-124.
5. Langton C.G. Artificial Life//Artificial Life.— Vol. IV of Santa Fe Institute Studies in Science of Complexity.— Reading, MA: Addison-Wesley, 1988.— Pp. 1 -47.
6. Кольчугина Е.А., Заваровский К.В. Применение методов генетического программирования к разработке web-интерфейсов//Прикладная информатика. — №5(41), 2012.- —Москва,ООО “Синергия Пресс”, 2012.—С. 64-74.
7. Bray D. Wetware: a Computer in Every Living Cell.— Yale University Press, New Haven &London, 2009.— 268 p.
8. Baldwin J.M. A New Factor in Evolution//American Naturalist.—Vol. 30, 1896.— Pp. 441-451.
9. Ray T.S. An Evolutionary Approach to Synthetic Biology: Zen and the Art of Creating Life//Artificial Life: an overview/ edited by Christopher G. Langton. —Cambridge, Massachusetts: The MIT Press, 1997.— Pp. 179-209.
10. Adami C. Ab Initio Modelling of Ecosystems with Artificial Life//Natural Resource Modelling.—Vol. 15, 2002.—Pp. 133-145.
11. Кольчугина Е.А. Неравновесное программирование//Известия высших учебных заведений. Поволжский регион. Технические науки.—№3(11), 2009.— Пенза, ИИЦ ПГУ, 2009.—С. 25-31
12. Кольчугина Е.А. Эволюция расписаний как средство разработки параллельного алгоритма поведения цифрового организма// Известия высших учебных заведений. Поволжский регион. Технические науки.—№1(5), 2008.— Стр. 45-52.
13. Tschudin C., Meyer T. Programming by Equilibria//15th Kolloquium Programmiersprachen und Grundlagen der Programmierung (KPS 2009), October 2009.— Vol. 2009-X-2. — Technische Universität Wien, 2009.— Pp. 37-46.
14. Schreckling D., Marktscheffel T. An Artificial Immune System Approach for Artificial Chemistries Based on Set Rewriting// Artificial Immune Systems. Proceedings of 9th International Conference, ICARIS 2010, Edinburgh, UK, July 26-29, 2010; Lecture Notes in Computer Science.—Vol. 6209. —Berlin-Heidelberg: Springer Verlag, 2010.— Pp. 250-263.

АЛГОРИТМЫ АППРОКСИМАЦИИ ДАННЫХ НАБЛЮДЕНИЙ НА ОСНОВЕ ТРИГОНОМЕТРИЧЕСКИХ МНОГОЧЛЕНОВ

М.А. Курако¹, К.В. Симонов²

¹Сибирский федеральный университет,

Институт космических и информационных технологий, mkurako@gmail.com

²Институт вычислительного моделирования СО РАН, simonovkv@icm.krasn.ru

Введение

Исследование посвящено разработке алгоритмов аппроксимации данных наблюдений сложных природных процессов. Рассмотрено несколько подходов к аппроксимации данных, сочетание которых позволяет строить аппроксимационные функции для сигналов любой сложности и дает возможность для эффективного решения задач восстановления данных, экстраполяции и локального прогноза [1-8].

Предложена вычислительная методика решения выделенных задач на основе разработанных алгоритмов обработки информации, позволяющих получать адекватные оценки изучаемых катастрофических явлений различной природы. Разработанное программное обеспечение используется для анализа и обработки информации в рамках системы геомониторинга природных катастрофических процессов [9-11], что позволяет обеспечивать своевременное и надежное предупреждение об опасности в режиме мягкого реального времени на современных вычислительных архитектурах.

1. Способы приближения эмпирических функций тригонометрическими многочленами. Основную задачу теории аппроксимации можно сформулировать следующим образом: на некотором точечном множестве β в пространстве произвольного числа измерений заданы функции $f(P)$ и $F(P, A_1, A_2, \dots, A_n)$ от точки $P \in \beta$, из которых вторая зависит ещё от некоторого числа параметров $A_1, A_2, \dots, A_n$. Эти параметры требуется определить так, чтобы уклонение в β функции $F(P, A_1, A_2, \dots, A_n)$ от функции $f(P)$ было наименьшим.

При этом, конечно, должно быть указано, что понимается под уклонением F от f или, как ещё принято говорить, под расстоянием между F и f . Например, если рассматриваются ограниченные функции, то в качестве расстояния между функциями удобно взять верхнюю грань в β модуля их разности. При таком определении расстояния для совокупности всех ограниченных в β функций оказываются справедливыми многие соотношения, которые мы имеем для точек обычного трехмерного пространства.

Последнее обстоятельство, с которым постоянно приходится сталкиваться при рассмотрении других классов функций и многих иных совокупностей (множеств), привело к созданию весьма важного понятия метрического пространства, так что при дальнейшем изложении совокупность β – метрическое или гильбертово пространство [5].

Таким образом, аппроксимация – математический метод, состоящий в замене одних математических объектов другими, в том или ином смысле близкими к

исходным объектам, но более простыми [1]. Аппроксимация позволяет исследовать количественные характеристики и качественные свойства объекта, сводя задачу к изучению более простых или более удобных объектов (например, таких, характеристики которых легко вычисляются, или свойства которых уже известны).

Основная задача исследования – разработка вычислительной технологии приближения эмпирической функции тригонометрическими многочленами и сравнительный анализ используемых формул приближения:

- приближение экспериментальных данных с помощью формул Валле–Пуссена, Фейера, Бернштейна–Рогозинского и выделение их особенностей;
- разработка алгоритмов приближения эмпирических функций.

В качестве основы аппроксимации экспериментальных данных используются ряды Фурье, поскольку такое приближение является классическим в математической теории. Ряды Фурье позволяют представить изучаемый процесс как определенный тригонометрический образ, что дает возможность выявить основные закономерности природного явления.

В работе рассматриваются формулы сумм Фейера, Валле–Пуссена и Бернштейна–Рогозинского [2, 4]. Ценность выбора этих методов состоит в том, что данные формулы довольно редко применялись в прикладных задачах. Также каждая из них имеет свои особенности и требования к степени приближения функции, что делает картину последовательных вычислений весьма разнообразной.

2. Алгоритмы аппроксимации

Существует множество алгоритмов аппроксимации функций, каждый из которых имеет свои отличительные особенности, достоинства и недостатки. При выборе конкретного способа приближения необходимо в первую очередь рассматривать тонкости исследуемого процесса: его природу, физические законы, описывающие динамику и позволяющие находить исключения, ошибки, особенности изучаемого явления.

Разработанные алгоритмы позволяют решать прикладные задачи, в ходе которых проявляются исключения и новые условия. Немаловажна структура данных, описывающая процесс, по которым строится аппроксимируемая функция. Физический смысл, количество, в какой математической форме представлены изучаемые значения – все перечисленное немаловажно и определяют выбор метода приближения [3].

Алгоритмы аппроксимации основаны на применении формул сумм Фейера, Валле–Пуссена и Бернштейна–Рогозинского. Использование рядов Фурье в процессе приближения функции облегчает вычислительные процедуры, так как все практические расчеты ведутся на основе одних и тех же коэффициентов: их можно применять в разных способах суммирования и объективно судить об эффективности того или иного метода.

Алгоритм аппроксимации на основе формулы суммы Фейера. Рассмотрим алгоритм аппроксимации функций на основе суммы Фейера. Алгоритм аппроксимации сводится к двум важным этапам: построение ряда Фурье для аппроксимируемой непрерывной функции f (не обязательно сходящегося к этой функции) и вычисление среднего арифметического первых частичных сумм этого ряда [4]:

$$\sigma_n(x; f) = \frac{S_0(x; f) + S_1(x; f) + \dots + S_{n-1}(x; f)}{n}, \quad (1)$$

где

$$S_n(x) = \frac{a_0}{2} + \sum_{k=1}^n (a_k \cos kx + b_k \sin kx).$$

Среднее арифметическое $\sigma_n(x; f)$ называют суммой Фейера n -го порядка, соответствующей данной функции $f(x)$. Название этих сумм дано в честь венгерского математика Л. Фейера (1880–1959).

Алгоритмическая схема применения формулы Фейера:

- вычисление частичных сумм Фурье на каждом отрезке (для кусочно-непрерывных функций);
- подстановка найденных на предыдущем шаге сумм в (1) и вычисление значения приближенной функции в заданной точке x ;
- построение графика полученной функциональной зависимости (необязательно, может использоваться для визуального контроля точности аппроксимации).

Формула (1) позволяет строить аппроксимации на основе частичных сумм Фурье. Этот способ наименее вычислительно труден (вычисление последующих частичных сумм возможно с использованием предыдущих сумм без полного пересчета), но весьма рационален, что способствует его активному использованию на практике.

Алгоритм на основе формулы суммы Валле-Пуссена. Суммами Валле-Пуссена порядка (n, p) называют выражения вида [4]:

$$V_{np} = \frac{S_n(x; f) + \dots + S_{n+p-1}(x; f)}{p}, \quad (2)$$

Структурно алгоритм вычисления суммы Валле-Пуссена мало отличается от аналогичного алгоритма для вычисления суммы Фейера. Основное отличие состоит в необходимости вычисления сумм с большими номерами, при этом их количество может задаваться отдельно.

Данная формула, как и предыдущая, работает с найденными частичными суммами Фурье. Разница состоит в том, что меняется порядок выбранных для работы степеней точности. Возьмём $n = p$. Данный способ вычисления подобен предыдущему по сложности, но все же позволяет с другой стороны взглянуть на процесс приближения функции.

Алгоритм на основе формулы суммы Бернштейна-Рогозинского. Рассмотрим формулу приближения функции Бернштейна-Рогозинского. Пусть, как и раньше, $S_n(x; f)$ – частичные суммы Фурье функции $f(x)$. Положим

$$B_n^*(x; f) = \frac{1}{2}[S_n(x + \alpha_n; f) + S_n(x - \alpha_n; f)] \quad (3)$$

где $\alpha_n > 0$ ($n = 0, 1, 2, \dots$).

Приближение периодических функций тригонометрическими многочленами $B_n^*(x; f)$ называется приближением по методу Бернштейна–Рогозинского.

Структурно алгоритм вычисления суммы Бернштейна–Рогозинского отличается от предыдущих алгоритмов изменением во втором шаге, где в качестве параметра α_n нужно взять некоторое фиксированное значение (в статье используется $\alpha_n = 0,001$).

Метод аппроксимации с помощью суммы Бернштейна–Рогозинского похож на метод Дирихле, но в некоторых случаях имеет лучшую сходимость, что удобно для сравнения с подобными способами.

Заключение

Таким образом, рассмотрены три способа приближения функции тригонометрическими многочленами: формулу сумм Фейера, Валле–Пуссена и Бернштейна–Рогозинского. Получены приближения искомых функций на реальных экспериментальных данных. Сравнение трех методов показано, что в формуле Валле–Пуссена особое внимание уделяется гармоникам малой частоты. Ее частный случай – формула суммы Фейера – восстанавливает значения непрерывных функций в их точках, при этом гармоники низших номеров вносят вклад в приближение больше высших. Сумма Бернштейна–Рогозинского очень похожа на метод Дирихле, но работает с симметричными полусуммами и также в среднем не учитывает степень точности.

Составлены алгоритмы применения каждой из формул. Далее разработанные алгоритмы используются как единая вычислительная методика для анализа эмпирических данных геомониторинга процесса подготовки сильного землетрясения.

Список литературы

1. Ахиезер Н.И. Лекции по теории аппроксимации: научное издание / Н.И. Ахиезер. – М.: Наука, 1965.
2. Бари Н.К. Тригонометрические ряды / Н.К. Бари – М.: Наука, 1961.
3. Бхаттачария Р.Н. Аппроксимация нормальным распределением и асимптотические разложения / Р. Н. Бхаттачария, Рао Р. Ранга. – М.: Наука, 1982.
4. Гутер Р.С. Элементы теории функций. Функции действительного переменного. Приближение функций. Почти–периодические функции / Р.С. Гутер, Л.Д. Кудрявцев, Б.М. Левитан. – М.: ГИФМЛ, 1963.
5. Жук В.В. Тригонометрические ряды Фурье и элементы теории аппроксимации / В.В. Жук, Г.И. Натансон. – Л.: Изд–во Ленингр. ун–та, 1983.
6. Зенкевич О. Конечные элементы и аппроксимация / О. Зенкевич, К. Морган. – М.: Мир, 1986.
7. Зигмунд А. Тригонометрические ряды: в 2 т. / А. Зигмунд. – М.: Мир, 1965.
8. Лоран П.–Ж. Аппроксимация и оптимизация / П.–Ж. Лоран. – М.: Мир, 1975.
9. Любушин А.А. Анализ данных систем геофизического и экологического мониторинга / А.А. Любушин. – М.: Наука, 2007.
10. Сибгатулин В.Г. Оценка сейсмической опасности юга Центральной Сибири: В.Г. Сибгатулин, К.В. Симонов, С.А. Перетокин. – Красноярск: КНИИГиМС, 2004.
11. Соболев Г.А. Физика землетрясений и предвестники / Г.А. Соболев, А.В. Пономарев. – М.: Наука, 2003.

РАЗНООБРАЗИЕ ОКРУЖАЮЩЕЙ СРЕДЫ КАК ФАКТОР, ОПРЕДЕЛЯЮЩИЙ ЗАМЕДЛЕНИЕ РАЗВИТИЯ НЕКОТОРЫХ НЕЙРОДЕГЕНЕРАТИВНЫХ ЗАБОЛЕВАНИЙ¹

А.В.Моргун¹, А.Б.Салмина¹, Н.В.Кувачева¹, Е.Д.Хилажева¹, М.Г.Садовский²,
Е.А.Пожиленкова¹

¹Красноярский государственный медицинский университет,
*441682@mail.ru; allasalmina@mail.ru; natalya.kuvacheva@gmail.com;
elena.hilazheva@mail.ru*

²Институт вычислительного моделирования СО РАН, *msad@icm.krasn.ru*

Болезнь Альцгеймера (БА) — грозное нейродегенеративное заболевание, фактически не поддающееся в настоящее время эффективному лечению. БА — характеризуется выраженными поведенческими нарушениями в социальной сфере (потеря социальной памяти, нарушение социальных связей, агрессия) и несоциальной сфере (нарушения пространственной памяти, трудности в запоминании, развитие тревожности и депрессии), что имеет своим результатом нарушение социализации и коммуникации [4]. Причина и механизмы развития данной болезни на клеточно-молекулярном уровне выяснены достаточно полно и хорошо; это знание, однако, не позволяет — на современном уровне развития медицины — проводить эффективное лечение. Основная причина болезни — интрацеребральное отложение патологического амилоидного белка, или бета-амилоид-протеина. В результате отложения или изменения белка ослабляется клеточный метаболизм, что способствует развитию нарушений метаболизма и функционирования клеток. Прежде всего нарушается способность к образованию межсинаптических связей, а также критически уменьшается количество нервных клеток.

Несмотря на то, что причины и механизмы заболевания на клеточно-молекулярном уровне описаны достаточно полно, можно с уверенностью утверждать, что заболевание это носит комплексный характер. Его лечение тем более должно быть комплексным и включать в себя не только устранение конкретных дефектов и поражений на клеточном уровне во вполне определённых клетках мозга, но и включать в себя иные реабилитирующие воздействия; основная гипотеза настоящей работы заключается в том, что таким ключевым фактором, замедляющим развитие болезни Альцгеймера (и даже предотвращающим её раннее развитие) является богатая окружающая среда. Иными словами, жизнь в насыщенной сенсорными и когнитивными процессами среде будет способствовать замедлению развития указанной болезни. В настоящей работе приведены предварительные результаты, подтверждающие данную гипотезу.

Исследование проводилось на модельном организме — крысах линии Wistar с исходной массой тела 300 – 350 г на основе соблюдения принципов гуманности, изложенных в Директиве Европейского сообщества (86/609/ЕС), с одобрением

¹ Работа выполнена при поддержке гранта Президента РФ для государственной поддержки ведущих

локального этического комитета КрасГМУ им. проф. В.Ф. Войно-Ясенецкого (заключение 35/2011). Возраст животных составил 7 – 9 месяцев (молодые особи, 12 особей), что соответствует периоду т.н. социального созревания этих животных и характеризует окончание периода формирования основных функций головного мозга, и 23 – 25 месяцев (стареющие особи, также 12 особей), что соответствует началу старения основных систем организма у крыс. Животных содержали в клетках со свободным доступом к воде и корму при постоянной температуре $21 \pm 1^\circ\text{C}$ и регулярном световом цикле – 12 ч день / 12 ч ночь. Дизайн исследования представлен на рисунке 1.

Молодые и стареющие крысы содержались в разных условиях. Для создания обогащенной среды использован стандартный протокол, подразумевающий длительное (60 дней) содержание животных в условиях многостимульной среды. Обогащенная среда представляла собой клетку размером $78 \times 48 \times 39$ см, разделённую на два этажа, сообщающихся при помощи лестницы. Клетка была заполнена пластиковыми туннелями, домиками, гамаками, лестницами, коробками, упражняющими «беличьими» колесами. В каждой клетке для социального обогащения размещалось по 12 животных.

У части животных, после нахождения в условиях ОС и стандартных условиях, проводили моделирование БА



Рис. 1. Дизайн эксперимента: В – выделение прогениторных клеток и культивирование нейросфер; xCell – культивирование нейросфер с применением технологии «xCelligence» (Roche, Германия).

Моделирование болезни Альцгеймера осуществляли интрагиппокампальным введением бета-амилоида по стереотаксическим координатам мозга в СА1 зону. Бета-амилоид 1-42 (Sigma-Aldrich, USA) растворяли в PBS (фосфатно-солевом буфере) до концентрации 2 мкг/мкл с последующей агрегацией в термостате при 37°C в течение 7 дней. С каждой стороны гиппокампа в зону СА1 вводили 5 мкл бета-амилоида [5]. Оценку признаков БА проводили, начиная с 10 суток [6] после оперативного вмешательства. Верификацию модели болезни Альцгеймера осуществили окраской тиофлавином S. После введения амилоида в ткани головного мозга наблюдались флуоресцирующие амилоидные бляшки зеленого цвета. Таким образом, получили шесть групп животных:

- 1) молодые животные, содержащиеся в стандартных условиях;
- 2) молодые животные, содержащиеся в условиях ОС;

- 3) старые животные, содержащиеся в стандартных условиях;
- 4) старые животные, содержащиеся в условиях ОС;
- 5) старые амилоидные животные, содержащиеся в стандартных условиях (с экспериментальной БА);
- 6) старые амилоидные животные, содержащиеся в условиях ОС (с экспериментальной БА).

Кроме этого, было две контрольных группы животных — ложнооперированные животные и чистая питательная среда. Группы контроля позволили исключить влияние операционного стресса и самой культуральной среды на результаты эксперимента.

Выделение и культивирование прогениторных клеток

Использовалась основная культуральная среда NeuroCult® NS-A Proliferation Medium производства Stemcell® с добавлением гепарина, основного фактора роста фибробластов и эпидермального фактора роста. Животных декапитировали после охлаждения на льду и производили забор головного мозга, который переносился в 35 мм культуральную чашку, содержащую раствор 2 % глюкозы в PBS. Отделяли интересующие регионы (гиппокамп, стенки боковых желудочков) и переносили в культуральную чашку с раствором 2 % глюкозы в PBS (манипуляции проводятся на льду), и иссекали до размеров в 1 мм³. После окончания диссекции, кусочки ткани помещались в 14 мл коническую пробирку в свежий раствор 2 % глюкозы в PBS на 1 минуту до осаждения кусочков ткани с последующим удалением супернатанта.

Оставшуюся ткань ресуспензировали в 1 мл «конечной» среды NeuroCult® NS-A Proliferation путем тритурации ткани стерильным пластиковым наконечником до получения однородной суспензии клеток с последующей добавкой еще 1 мл «конечной» среды NeuroCult® NS-A Proliferation к суспензии клеток. Через 1-2 минуты, после осаждения неразделенных кусочков ткани собирали супернатант и переносили его в новую стерильную 14 мл пробирку. Супернатант центрифугировали при 150 g в течение 5 минут. Удаляли супернатант и добавляли 1 мл «конечной» среды NeuroCult® NS-A Proliferation с последующей повторной тритурацией.

Проводили подсчёт количества клеток с помощью гемацитометра и определяли жизнеспособность клеток с трипановым синим в разведении 1/5 или 1/10 в зависимости от количества анализируемой ткани. Клетки плотностью $(1.2-1.5) \times 10^5$ жизнеспособных клеток/мл вносили в культуральные флаконы T-25 см², куда добавляли 10 мл «конечной» среды NeuroCult® NS-A Proliferation. Инкубация клеток проводилась в условиях CO₂-инкубатора при 5 % CO₂ и 37°C. На следующие сутки наблюдали образование нейросфер (клетки пролиферируют как сфероиды, называемые нейросферами, которые обычно отделяются с поверхности культурального флакона или свободно плавают в нём). Жизнеспособные нейросферы на фазовом контрасте представляют собой полупрозрачные скопления множества клеток, несущие на своей поверхности микрошипы. Спустя 3–4 суток с момента посева (в зависимости от плотности и размера сфер) нейросферы готовы к субкультивированию.

Для пересева нейросфер культуральную среду с клетками помещали в пробирку и центрифугировали 5 минут при 90g. Удаляли супернатант, оставляя около 150 мкл среды, мягко тритурировали осадок пластиковым наконечником, определяли клеточность с помощью гемацитометра и засеивали клетки в лунки прибора «xCelligence» с плотностью $(1.2 - 2.5) \times 10^4$ жизнеспособных клеток/мл в 200 мкл «конечной» среды NeuroCult® NS-A Proliferation.

Изучение особенностей нейрогенеза крыс проводили с помощью прибора системы для проведения клеточного анализа «xCelligence» (Roche, Швейцария). Присутствие клеток на электродах в лунках планшета влияет на локальное состояние ионного окружения, что приводит к изменению сопротивления на электродах и увеличению клеточного индекса, который является расчетным показателем и зависит от количества, размеров клеток и является импедансозависимым.

Опишем подробнее структуру данных, полученных в ходе эксперимента и метод их обработки. Для каждой из экспериментальных групп бралось по 4 лунки, что и порождало массив экспериментальных данных. При этом замеры клеточного индекса во всех лунках проводились каждые 5 минут с нулевого часа эксперимента по 4,5, а затем — каждые 15 минут.

Для каждого из препаратов производился замер клеточного индекса *CI*; данный индекс является числовым значением, генерализованно отражающим состояние пробы; показания индекса брались каждые пятнадцать минут, в течение суток. Тем самым, исходная база данных представляла собой таблицу, в которой было представлено 32 экспериментальных объекта (строки), включая контроль и 132 экспериментальные точки (для каждого объекта). Заметим, что формально экспериментальные данные можно рассматривать как временные ряды; детальное обсуждение этого вопроса приведём ниже. Главной проблемой в условиях описанного эксперимента было существенное (в разы) превышение размерности пространства данных над числом объектов (лунок), доступных для анализа.

Основная задача настоящей работы состояла в извлечении знаний из данных той структуры, которая описана выше. Обработка данных проводилась в несколько этапов. На первом этапе решалась двойственная задача: все экспериментальные объекты были «назначены» показателями зависимых переменных, а моменты времени, в которые брались замеры индекса *CI* — объектами. Первым вопросом стоял вопрос о группировке моментов времени в кластеры, в рамках которых данные можно было считать подобными либо слабо различимыми в «пространстве мышек». Иными словами, данную процедуру можно считать одним из вариантов сегментирования временного ряда.

Все процедуры кластеризации проводились двумя методами: методом динамических ядер (*K-means* в англоязычной терминологии) и методом упругих карт; для этого использовалась программа *ViDaExpert* (<http://bioinfo-out.curie.fr/projects/vidaexpert/>). Кратко опишем эти методы. Метод динамических ядер является классическим методом классификации без учителя [1]; кратко он заключается

в следующем. Всё множество объектов случайным образом разбивается на K классов (групп), затем для каждого класса определяется ядро — среднее арифметическое всех точек, попавших в класс. После этого для всех точек, вне зависимости от того, к какому классу они принадлежат, вычисляется расстояние от неё до каждого из ядер; если точка оказалась ближе всего к ядру того класса, к которому она первоначально принадлежала, то она остаётся в этом классе. Если же точка из l -го класса оказалась ближе к ядру m -го класса, то она переопределяется в этот класс; здесь, очевидно, $1 \leq l, m \leq K$. После того, как все точки оказались переопределены, повторяется вычисление (теперь уже других) динамических ядер, после чего проводится процедура переопределения. Такое «перекладывание» из класса в класс повторяется до тех пор, пока все точки не перестанут переходить из класса в класс. Заметим, что данная процедура всегда сходится. Строго говоря, за этим следует процедура проверки различимости классов, однако мы не проводили её в рамках настоящего исследования.

У метода динамических ядер есть несколько важных особенностей, делающих его применение затруднительным. Во-первых, заранее неочевидно число классов, на которые надо разбивать исходное множество точек. Во-вторых, заранее не гарантирована устойчивая сходимость к одному и тому же распределению точек по классам, для разных реализаций метода; напомним, что построение классификации начинается со случайного распределения точек по K классам. В-третьих, во многих задачах всё же следует проверять различимость классов, объединяя два (или более) неразличимых.

Второй метод, использованный нами для анализа полученных данных, — визуализация и кластеризация с помощью упругой карты [2]. Идея метода заключается в приближении многомерных данных многообразием малой размерности; в нашем случае — многообразием размерности 2 (т.е. плоскостью). Поясним кратко сам метод. Всё начинается с выделения первых двух главных компонент в распределении точек в пространстве. Напомним, содержательно первые две главные компоненты — это два перпендикулярных направления, вдоль по которым наблюдается самое сильное «растяжение» данных. Затем на этих двух прямых как на осях строится плоскость; каждая точка данных проектируется на эту плоскость и затем связывается «пружинкой» (связью) с точкой проекции. После этого самой плоскости разрешается растягиваться и гнуться; единственное условие — у неё не должна меняться топология. В распоряжении исследователя есть два подгоночных параметра: жёсткость пружинок и эластичность самой плоскости. Систему отпускают, давая ей принять конфигурацию, соответствующую минимальной суммарной энергии всех растяжений.

Затем положение каждой точки переопределяется: вместо проекции объект отображается в ту точку на деформированной поверхности, которая ближе всего (в смысле используемого расстояния) к объекту. Наконец, так определённая упругая карта обратным нелинейным преобразованием «распрямляется», тем самым обеспечивая визуализацию многомерных данных. Описав методы анализа, перейдём к изложению результатов исследования.

Результаты и обсуждение

Одна из проблем анализа полученных данных заключается в «проклятии размерности»: данные, представляющие собой временной ряд, фактически обладают размерностью (число моментов времени наблюдений), заметно превосходящей число объектов, за которыми велось наблюдение. Это обстоятельство связано как с технологией самого эксперимента, так и с его протоколом и изменить его невозможно. Здесь возникает необходимость выбора метода, который бы позволил извлечь знания из имеющегося экспериментального материала. Стандартный подход состоит в том, чтобы использовать не весь временной ряд, а некоторые его сегменты. В теории временных рядов такой подход тесно связан с проблемой их сегментирования [3].

В рамках настоящей работы использовались два подхода к такого рода сегментированию: первый использует условно «наивные» основания для сегментирования, второй основывается на подходе, связанном с построением упругой карты. Опишем их подробнее.

Собственно, задача сегментирования временного ряда состоит в выделении в нём (достаточно протяжённых) фрагментов, в пределах которых этот ряд можно аппроксимировать какой-нибудь интуитивно прозрачной (и сравнительно простой) зависимостью; например, можно выделять участки, на которых поведение временного ряда носит стационарный характер, либо хорошо приближается экспонентой (затухание того или иного процесса). Реализация такого подхода требует описания способов выявления таких фрагментов и критических точек — тех моментов времени, в которые временной ряд меняет характер своего поведения. Как правило, вторая задача решается сравнительно легко: это такие точки, в которых кривая, соответствующая временному ряду, испытывает нечто вроде излома. Например, можно фиксировать некоторый уровень изменения производной и так определять эти точки. Именно такой подход и был использован в рамках настоящей работы для первичного анализа полученных данных (см. раздел «Первичный анализ данных»).

Другим возможным подходом является анализ на основе тех или иных более строгих процедур сегментирования временного ряда. Не обсуждая здесь всего разнообразия возможных методов и приёмов (см. подробнее в [3]), опишем тот, который использовался в настоящей работе. Этот приём основан на кластеризации точек временных рядов методами нелинейной статистики; в нашем случае мы использовали метод упругих карт [2]. Сам по себе метод её построения описан выше. Поясним здесь его приложение к проблеме сегментирования имеющихся в распоряжении исследователя временных рядов.

Во-первых, отметим, что имеющиеся в нашем распоряжении временные ряды однородны: они имеют одинаковую длину и данные определены в одни и те же моменты времени. Поскольку число точек ряда (130) заметно больше числа экспериментальных объектов (32 лунки), постольку прямой анализ распределения лунок в пространстве временных точек, будучи формально возможным, даст

бессмысленный результат: все экспериментальные точки могут быть с абсолютной точностью описаны некоторой гиперплоскостью (размерности 32). Понятно, что полученная таким образом гиперплоскость может отражать внутреннюю структуру данных, а может и не отражать.

В этой ситуации мы выявляли те фрагменты рядов, длина которых уже позволяла проводить «прямой» анализ экспериментальных данных. Для этого сначала решалась двойственная задача: строилась (как описано выше) упругая карта, для которой «независимыми» переменными (объектами) выступали не экспериментальные лунки, а моменты времени. «Координатами», в которых изучалось распределение моментов времени, выступали как раз экспериментальные лунки. Тем самым, мы получали кластеры моментов времени, которые оказывались «близкими» в координатах, состоящих из лунок. Затем анализировалось уже распределение лунок в пределах тех точек, которые были выбраны по результатам описанной выше кластеризации.

Первичный анализ данных

Анализ данных роста культуры прогениторных клеток (ПК), выделенных от здоровых животных, содержащихся в стандартных условиях, показал наличие 5 основных областей, характеризующих принципиально отличающиеся друг от друга фазы развития клеточной популяции: область А — осаждение клеток под действием силы тяжести; В — фаза относительной стабильности, возможно, связанная с накоплением внутренних резервов клеток для последующей пролиферации; С — фаза активного образования сфероидных колоний клеток (нейросфер); D и E — области, характеризующиеся медленной пролиферацией образовавшихся нейросфер [7].

Данные, полученные от здоровых животных и животных с экспериментальной БА, содержащихся в стандартных условиях (рис. 1), показывают, что область А отличается по максимальным значениям клеточного индекса (0.048 ± 0.015 и 0.019 ± 0.010 соответственно) и скорости его изменения (1.16 ± 0.34 против 0.62 ± 0.29 соответственно) (таблица). Поскольку клеточный индекс зависит от площади соприкосновения клеток с поверхностью лунок, такие отличия могут свидетельствовать о меньших размерах ПК у животных с экспериментальной БА, что согласуется с данными других исследователей [8]. Период стабильности (область В) у клеток животных с экспериментальной БА значительно короче, чем у здоровых, и имеет меньшее значение клеточного индекса (0.013 ± 0.009 и 0.044 ± 0.001 соответственно), что также может характеризовать морфологические особенности клеток.




Рис. 1. Типичные кривые роста популяции ПК головного мозга, полученных от здоровых животных и животных с экспериментальной БА. Область А — фаза осаждения ПК, В — фаза стабильности ПК, С — фаза интенсивного образования нейросфер, D — фаза стабильности нейросфер, E — фаза пролиферации нейросфер.

Пролиферация ПК сопровождается образованием нейросфер, флотирующих в растворе культуральной среды. При всплывании таких конгломератов клеток происходит уменьшение клеточного индекса до отрицательных значений. У животных с экспериментальной БА образование нейросфер идет медленнее: область С составляет около 10 ч, что в 2 раза больше, чем у здоровых животных, и имеет чуть меньшую скорость изменения клеточного индекса (0.35 ± 0.07 и 0.47 ± 0.03 соответственно).

Фазы стабилизации нейросфер и увеличения их размеров, сопровождающегося возрастанием клеточного индекса (области D и E), у клеток, выделенных из мозга животных с экспериментальной БА, практически нет: со временем идет постепенное снижение клеточного индекса, не такое резкое, как в области С. Это может быть связано с медленным ростом нейросфер.

Поведение ПК, полученных от животных с экспериментальной БА, содержащихся в ОС, было сходным с ПК здоровых животных из ОС (рис. 2): схожие максимальные значения клеточного индекса (0.159 ± 0.053 и 0.165 ± 0.016 соответственно) и скорости его изменения в области А, продолжительность стабильной области В (почти 7 ч), минимальные значения индекса в области С (0.070 ± 0.041 и 0.057 ± 0.016 соответственно). Исключением, как и в случае с животными из стандартных условий, являлась область E, в которой не наблюдали роста клеточного индекса. Интересен тот факт, что скорость образования нейросфер (область С) у животных с БА в ОС и в стандартных условиях была практически одинаковой (0.38 ± 0.03 и 0.35 ± 0.07 ; таблица).




Рис. 2. Типичные кривые роста популяции ПК головного мозга, полученных от животных, содержащихся в стандартных условиях и в ОС.

В ходе исследования выявлено, что у здоровых животных по сравнению с животными с экспериментальной БА отмечается более динамичное образование нейросфер, что свидетельствует о большем количестве ПК и их выраженном репаративном потенциале.

Содержание животных в условиях ОС значительно влияет на свойства ПК. Мы предполагаем, что в области В существует равновесие между количеством оседающих и всплывающих клеток, которые образуют нейросферы. Под влиянием ОС при одинаковом количестве клеток у животных с БА плато В становится более продолжительным, что связано с увеличением размера клеток, а значит, с увеличением скорости оседания в среде, что подтверждается более высоким клеточным индексом, чем у клеток животных с БА, содержащихся в стандартных условиях. Длительность данного периода предположительно связана с большей стабильностью клеток, крупными размерами и большим количеством зрелых клеток. Часть их сохраняет способность к образованию нейросфер (присутствие области С), но их количество меньше, о чем свидетельствует положительное значение клеточного индекса в области D у «обогащенных» клеток по сравнению с отрицательным значением у «стандартных» клеток, при этом наблюдается статистически значимая разница ($p < 0.05$). В то же время скорость образования нейросфер (скорость изменения клеточного индекса в области С) под влиянием ОС у животных с БА практически не меняется, что говорит об ограниченном положительном влиянии условий содержания на пролиферативную способность ПК, но длительность фазы пролиферации приближается к показателям здоровых животных. Схожие изменения профиля поведения ПК наблюдаются в указанные периоды и у здоровых животных, содержащихся в ОС.

Анализ данных, полученных от старых животных, содержащихся в стандартных условиях (рис. 3), показал, что область А незначительно отличается по максимальным значениям от молодых здоровых животных ($0,064 \pm 0,030$ и $0,048 \pm 0,015$,

соответственно), а, следовательно и скорости изменения клеточного индекса: $1,46 \pm 0,53$ против $1,16 \pm 0,34$, соответственно. Период стабильности (область В) у клеток старых животных в 2 раза длиннее, чем у молодых и имеет несколько большее значение клеточного индекса: $0,065 \pm 0,001$ и $0,044 \pm 0,001$, соответственно. У старых животных образование нейросфер идет медленнее, при этом отличия статистически значимы ($p < 0,05$): область С составляет около 8 часов, что на 3 часа больше, чем у молодых животных, и имеет почти в 2 раза меньшую скорость: $0,26 \pm 0,03$ и $0,47 \pm 0,03$ ($p < 0,05$), соответственно. Фазы стабилизации нейросфер и увеличения их размеров, сопровождающегося возрастанием клеточного индекса (области D и E) у клеток, выделенных из мозга стареющих животных, практически нет: со временем идет постепенное снижение клеточного индекса, не такое резкое, как в области С. Это может быть связано с медленным ростом нейросфер, что подтверждается визуальной оценкой размера нейросфер, полученных от различных возрастных групп животных, на инвертированном микроскопе.




Рис. 6. Сравнительный анализ роста популяции прогениторных клеток головного мозга, полученных от животных, содержащихся в обычной и обогащенной среде.

Под влиянием обогащенной среды прогениторные клетки головного мозга, полученные от стареющих животных, содержащихся в обогащенной среде, показывают поведение, сходное с клетками молодых здоровых животных из обогащенной среды: схожие максимальные значения клеточного индекса ($0,134 \pm 0,018$ и $0,159 \pm 0,016$, соответственно) и скорости его изменения в области А, продолжительность стабильной фазы В (почти 7 часов), минимальные значения индекса в области С ($0,054 \pm 0,023$ и $0,057 \pm 0,016$, соответственно). Исключение, как и в случае с животными из стандартных условий, является область Е, в которой не наблюдается роста клеточного индекса. Интересным является тот факт, что скорость образования нейросфер (область С) у старых животных в обогащенной среде и стандартных условиях была практически одинаковой ($0,28 \pm 0,03$ и $0,35 \pm 0,05$).

В ходе исследования выявлено, что у молодых животных по сравнению со стареющими, отмечается более динамичное образование нейросфер, что свидетельствует о большем количестве прогениторных клеток и их выраженном репаративном потенциале. Морфологически образовавшиеся сфероиды также отличаются: у стареющих крыс нейросферы меньше по размерам (в диаметре), они менее структурированы и менее стабильны, для их образования требуется больше времени. Это может свидетельствовать о том, что формирование нейросфер у молодых животных обеспечивается, в основном, более пролиферативно активными клетками с коротким клеточным циклом.




Рис. 1. Упругая карта распределения моментов времени, построенная в координатах «стандартной среды» (12 «координат»: все молодые в стандартных условиях, все стареющие в стандартных условиях и все амилоидные в стандартных условиях).

Содержание животных в условиях ОС значительно влияет на свойства прогениторных клеток. Мы предполагаем, что в фазу В существует равновесие между количеством оседающих и всплывающих клеток, которые образуют нейросферы. Под влиянием ОС при одинаковом количестве клеток у стареющих животных плато В становится более продолжительным, что связано с увеличением размера клеток, а значит увеличением скорости оседания в среде, что подтверждается более высоким клеточным индексом, по сравнению с клетками стареющих животных, содержащихся в стандартных условиях. Длительность данного периода, по нашему предположению, связана с большей стабильностью клеток, крупными размерами и большим

количеством зрелых клеток. Часть их сохраняет способность к образованию нейросфер (присутствие фазы С), но их количество меньше, о чем свидетельствует положительное значение клеточного индекса в периоде D у «обогащенных» клеток в сравнении с отрицательным значением у «стандартных» клеток, при этом наблюдается статистически значимая разница ($p < 0,05$). В тоже время, скорость образования нейросфер (скорость изменения клеточного индекса в фазу С) под влиянием обогащенной среды у старых животных практически не меняется, что говорит об ограниченном положительном влиянии условий содержания на пролиферативную способность прогениторных клеток. Подобные изменения профиля поведения прогениторных клеток наблюдаются в указанные периоды и у молодых животных, содержащихся в ОС.

Анализ данных методом кластеризации на основе упругой карты

На рисунке 1 показано распределение моментов времени в «координатах» экспериментальных лунок (двойственная задача). Хорошо видно, что все моменты времени четко разбиваются на три зоны: две из них представляют собой явно выраженные кластеры (располагаются по краям упругой карты), а одна зона представляет собой своеобразный переход от одного кластера к другому (точки в нижней части карты). Именно эти временные точки, не попавшие ни в один из кластеров, были использованы для дальнейшего прямого анализа.




Рис. 2. Упругая карта распределения моментов времени, построенная в координатах «обогащённой среды» (12 «координат»: все молодые, стареющие и амилоидные в условиях обогащённой среды).

Сразу же отметим, что указанные моменты времени, по которым проводился прямой анализ, фактически полностью совпадают с т.н. фазой С, выделяемой в рамках «наивного» сегментирования, полученного при первичной обработке данных (моменты времени с 4,4 часа по 9,1 час). Это совпадение косвенно подтверждает, что фаза С, определяемая скорее исходя из физиологических и биологических соображений, тем не менее оказывается релевантной структуре тех данных, которые имеются в распоряжении: иными словами, фаза С не просто определяется физиологией, но и адекватно описывает важный эпизод в динамике пролиферации клеток в лунках, и здесь возможен содержательный «прямой» анализ многомерных данных с размерностью пространства, превосходящей число экспериментальных точек.

Результаты кластеризации для двойственной задачи, но определяемой в «координатах» обогащённой среды выявляют не только фазу С, но и фазу А, которая не видна на упругой карте, построенной в «координатах» стандартной среды (моменты времени с 10,8 часа по 14,3 часа для фазы С и с 0 часа по 1,8 часа для фазы А). Этот факт представлен на рисунке 2. Гораздо важнее тот факт, что периоды времени, соответствующие фазе С для стандартных условий и для обогащённых условий, и выделяемые методом упругих карт (см. рисунок 1 и рисунок 2) оказываются несовпадающими. Такое несовпадение объясняется влиянием различия сред, в которых содержались экспериментальные животные (являвшиеся источником клеток).




Рис. 3. Упругая карта распределения лунок, построенная в координатах моментов времени (10 координат: данные взяты в моменты времени 4,8; 5,8; 6,8; 7,8; 8,8; 9,8; 10,8; 11,8; 12,8; 13,8 часа).

Различие структуры кластеров в «координатах» лунок для условий стандартной и обогащённой сред позволяет с высокой надёжностью утверждать, что влияние этого различия на характер протекания процессов в прогениторных клетках доказано.

Перейдём теперь к анализу экспериментальных данных, проведённому в «прямых» координатах (в координатах различных моментов времени). Для этого

выбирались моменты времени, соответствующие фазе С, определяемой в рамках «наивного» сегментирования; заметим, однако, что здесь выбор этих моментов был обоснован не биологическими соображениями, но определялись по статистическим свойствам исходных данных. Заметим, что общее число точек (моментов времени), попадающих в требуемый диапазон, всё ещё достаточно велико для надёжного проведения прямого анализа; тем самым, возникла задача уменьшения числа таких экспериментальных точек. Эта задача была решена наиболее простым способом: из всего множества подходящих точек бралось подмножество (общим числом в 8 моментов времени), которые выбирались равномерно по всему множеству подходящих точек.




Рис. 4. Упругая карта распределения лунок, построенная в координатах моментов времени (7 точек: 4,5; 5,3; 6,0; 6,8; 7,5; 8,3; 9,0 часа), для стандартных условий.

Следует отметить, что как продолжительность, так и взаимное расположение интервалов времени, соответствующих фазе С для стандартной и обогащённой сред, не совпадают (см. рисунок 3). Отчасти именно это обстоятельство привело к заметному увеличению числа экспериментальных точек, по которым можно было проводить прямой анализ. Поскольку по всем точкам, соответствующим стандартным и обогащённым условиям проводить анализ было невозможно, постольку мы уменьшили их число путём перехода к подмножеству. При этом подмножество строилось так, чтобы в него входили (более или менее пропорционально) точки, соответствующие фазе С для клеток, взятых от крыс, содержащихся в каждом из условий среды.

На Рис. 4 представлены результаты анализа влияния возраста на пролиферативную активность прогениторных клеток (также определяемых по точкам, соответствующим фазе С). Здесь показаны клетки от животных, содержащихся исключительно в стандартных условиях. Бралась клетки, полученные от молодых здоровых, молодых

«амилоидных» (экспериментальная модель болезни Альцгеймера) и здоровых стареющих животных. Чётко видно, что для такой группы экспериментальных животных главным фактором различия является возраст: это подтверждается тем, что молодые амилоидные и молодые здоровые клетки формируют один кластер, в то время как второй кластер сформирован исключительно клетками стареющих животных.

Подчеркнём при этом, что при построении упругой карты точки, соответствующие фазе С для всех групп лунок в координатах моментов времени для обогащённой среды не группируются на карте, но напротив, рассеяны по ней. Именно такое рассеяние и позволяет говорить о значительной роли условий содержания животных при нейродегенеративных заболеваниях и физиологическом старении.

Таким образом, в рамках настоящей работы показано, что результаты и выводы, полученные в рамках традиционных методов выявления различий между экспериментальными животными, являющимися донорами соответствующих клеток, подтверждаются также и методами анализа, основывающимися на подходах нелинейной статистики. Такое совпадение позволяет валидировать результаты, получаемые традиционными методами обработки данных, что важно, поскольку упомянутые традиционные методы часто подвергаются критике за низкий уровень обоснованности выводов, получаемых на их основе.

Ещё одним важным результатом данной работы является надёжно установленный факт влияния обогащённой среды на пролиферативную активность прогениторных клеток головного мозга экспериментальных животных. Иными словами, обогащённая среда существования является важным фактором снижения нейродегенеративных изменений головного мозга, что может оказаться важным этапом на пути создания эффективных методов профилактики подобных заболеваний.

Список литературы

1. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. Новосибирск: Наука, 1996. 276 с.
2. Зиновьев А. Ю., Питенко А. А., Попова Т. Г. Практическое применение метода упругих карт // Нейрокомпьютеры. — 2002. — № 4. — С. 31 – 39.
3. J.J.Murphy, Technical analysis of the financial markets. A comprehensive guide to trading methods and applications, New-York institute of finance, 1999. 530 p.
4. Crews L., Masliah E. Molecular mechanisms of neurodegeneration in Alzheimer's disease // Hum Mol Genet. — 2010. — Vol. 19(R1). — P. R12 – 20.
5. Li X., Yuan H.F., Quan Q.K., Wang J.J., Wang N.N., Li M. Scavenging effect of Naoerkang on amyloid beta-peptide deposition in the hippocampus in a rat model of Alzheimer's disease // Chin J Integr Med. — 2011. — Vol. 17, № 11. — P. 847 – 853.
6. Sipos E., Kurunczi A., Kasza A., Horváth J., Felszeghy K., Laroche S., Toldi J., Párducz A., Penke B., Penke Z. Beta-amyloid pathology in the entorhinal cortex of rats induces memory deficits: implications for Alzheimer's disease // Neuroscience. — 2007. — Vol. 147, № 1. — P. 28 – 36.
7. Кувачева Н.В., Моргун А.В., Комлева Ю.К., Салмина А.Б., Хилажева Е.Д., Окунева О.С., Дробушевская А.И., Кутищева И.А. Влияние обогащенной среды на ранние этапы развития прогениторных клеток головного мозга у молодых и стареющих крыс // Сибирский медицинский журнал (Иркутск). — 2013. — Т. 120, № 5. — С. 47 – 51.
8. He N., Jin W.L., Lok K.H., Wang Y., Yin M., Wang Z.J. Amyloid- β (1-42) oligomer accelerates senescence in adult hippocampal neural stem/progenitor cells via formylpeptide receptor 2 // Cell Death Dis. — 2013. — Vol. 4. — e924.

ПОСТРОЕНИЕ АЛГОРИТМОВ ДЛЯ АВТОМАТИЗИРОВАННОГО ПОДБОРА КРИТЕРИЕВ ДОСТОВЕРНОСТИ РАЗЛИЧИЙ ВЫБОРОК ДАННЫХ²

Л.И.Покидышева¹, М.С. Кайгородова²

¹Сибирский федеральный университет, *¹pok50gm@gmail.com*

²kaigorodovam@gmail.com

В настоящее время ученые используют множество методов математической статистики для анализа данных, полученных в ходе экспериментов [1-3]. При этом одной из наиболее часто встречающихся статистических задач является сравнение двух выборок и оценка достоверности их различий. Помимо этого нередко возникает необходимость оценить характер изменения того или иного показателя в одной или нескольких группах в разные периоды времени или выявить динамику изменения этого показателя. Для этого необходимо изучать критерии оценки достоверности различий и условия, при которых стоит применять тот или иной критерий. При этом выбираются наиболее популярные критерии, которые могут не подходить для обработки конкретных данных. Вследствие этого данные, полученные в результате исследований, могут быть ошибочными и приводить к непоправимым последствиям.

На сегодняшний день не существует готовых систем, способных автоматизировано подбирать критерии достоверности различий выборок для исследуемых данных. Разработка и применение такой системы позволило бы освободить специалиста узкой области от подбора критерия вручную, дало бы возможность сконцентрироваться на проблеме, решаемой исследованием, и значительно ускорило бы анализ данных.

Для проведения статистического анализа в первую очередь необходимо определить тип анализируемых данных и взаимосвязи между ними.

Существует достаточно большое количество критериев для определения достоверности различий выборок данных [1-4].

Были изучены: t-критерий Стьюдента (в случае несвязных и связных выборок), F-критерий Фишера, критерий знаков, T-критерий Вилкоксона, критерий Макнамары, U-критерий Манна-Уитни, Q-критерий Розенбаума, критерий χ^2 , критерий Фридмана, H-критерий Крускала-Уоллиса, S-критерий тенденций Джонкира.

При изучении критериев достоверности различий выборок было выявлено 4 наиболее существенных параметра, на основании которых должен проводиться подбор критериев для анализа заданных данных. К таким параметрам относятся:

- тип данных, содержащихся в выборках;
- распределение;
- связность выборок;
- число сравниваемых выборок.

На основании этих параметров было построено дерево, наглядно демонстрирующее, для каких данных, какие критерии следует применять (рисунок 1). Так как большинству групп данных соответствует более одного критерия, то было принято решение отсортировать их по мощности, начиная с самого слабого и заканчивая самым сильным.

Затем, опираясь на дерево подбора критериев, были написаны продукционные правила, при помощи которых выбираются критерии. Если выбрано несколько критериев, то они применяются поочередно, начиная с самого маломощного и

² Исследование выполнено при частичной финансовой поддержке РФФИ в рамках научного проекта №13-07-00814а.

заканчивая тем критерием, который обнаружит статистическую достоверность различий выборок, или самым мощным. При таком подходе возможно три различных исхода:

- первый критерий обнаружит достоверность различий. В этом случае результат анализа будет содержать только данные, полученные с помощью этого критерия.
- достоверность различий обнаружит не первый критерий. Тогда результат анализа будет содержать данные, полученные при помощи наиболее мощного критерия давшего отрицательный результат, и данные, полученные при помощи критерия давшего положительный результат;
- ни один критерий не обнаружит достоверность различий выборок. В этом случае результат анализа будет содержать данные, полученные при помощи самого мощного критерия.




Рисунок 1 – Дерево подбора критериев.

Далее была разработана структура системы (рисунок 2). Систему можно разделить на такие основные блоки как интерфейс и блок анализа выборок.




Рисунок 2 – Схема разработанной системы.

Был реализован алгоритм для определения возможных типов данных, содержащихся в одной из сравниваемых выборок, алгоритм для определения возможных типов данных, содержащихся в одной из сравниваемых выборок и другие.

Система написана на языке программирования python с применением библиотек: PyQt, Pandas, SciPy, StatsModels [5-8]. Все использованные библиотеки являются бесплатными и свободно распространяемыми.

При создании системы были написаны следующие классы: AppWindow, Dictionary, Analyzer, Parameters, Result, CreationDialog.

AppWindow – это класс главного окна системы. С его помощью данные загружаются, отображаются, редактируются, сохраняются и т.д.

Dictionary – это класс, предназначенный для работы со словарем порядковых данных. Он позволяет отображать, редактировать, сохранять словарь.

Analyzer – класс, который определяет параметры исследуемых данных, затем на их основе подбирает критерии, подходящие для их анализа, и с помощью подобранных критериев определяет достоверность различий выборок.

Классы Parameters, Result и CreationDialog – это не большие классы, предназначенные для получения каких либо данных от пользователя и отображения результата анализа данных.

Пользователь может загрузить и сохранить данные в файл с расширениями *.csv, *.xls, *.xlsx.

Разработанная система является кроссплатформенной. Для ее запуска на определенной операционной системе необходимо установить python2, python2-pyqt5 5.2.1-2, python2-pandas 0.13.1-1, python2-statsmodels 0.5.0-2, python2-scipy 0.13.3-2. В случае необходимости можно собрать исполняемый файл (.EXE).

После загрузки данных и проведения анализа программа выдает результаты в новом окне, изображенном на Рисунке 3.




Рисунок 3 – Окно для отображения результатов анализа

Разрабатываемая система предназначена для обнаружения статистически достоверных различий двух и более выборок. Применение данной системы позволяет значительно сократить время исследований.

Система протестирована на биомедицинских данных. Результаты полностью совпадают с результатами медицинских исследований.

Список литературы

1. Пакет статистической обработки археологических данных [Электронный ресурс] – Режим доступа: <http://www.sati.archaeology.nsc.ru/stat/>.
2. Реброва, О. Ю. Статистический анализ медицинских данных. Применение пакета прикладных программ STATISTICA / О.Ю. Реброва – Москва: МедиаСфера, 2002. – 312 с.
3. Математическая статистика для психологов. Учебник / Ермолаев О.Ю. – 2-е изд. Испр. – М. Московский психолого-социальный институт. Флинта 2003 – 336 с. – (Библиотека психолога)
4. Наследов, А. Д. Математические методы психологического исследования. Анализ и интерпретация данных: Учебное пособие / А. Д. Наследов – Санкт-Петербург: Речь, 2004. – 392 с.
5. Документация PyQt5 [Электронный ресурс] – Режим доступа: <http://pyqt.sourceforge.net/Docs/PyQt5/index.html>.
6. Документация Pandas [Электронный ресурс] – Режим доступа: <http://pandas.pydata.org/pandas-docs/stable/>.
7. Документация SciPy [Электронный ресурс] – Режим доступа: <http://docs.scipy.org/doc/>.
8. Документация StatsModels [Электронный ресурс] – Режим доступа: <http://statsmodels.sourceforge.net/devel/>.

СПЕЦИФИКА МАТЕМАТИЧЕСКОГО ОБЕСПЕЧЕНИЯ МУЛЬТИАГЕНТНЫХ ЭКСПЕРТНЫХ СИСТЕМ, ЗАДЕЙСТВОВАННЫХ ДЛЯ ОЦЕНКИ ЭФФЕКТИВНОСТИ РАБОТЫ УПРАВЛЯЮЩЕЙ КОМПАНИИ ЖИЛИЩНО-КОММУНАЛЬНОГО ХОЗЯЙСТВА

Пятковский О. И., Бир. А.А.

ООО «УК «Город»

Для решения неструктурированных проблем, которые выделяются при анализе эффективности работы управляющих компаний ЖКХ, было принято решение об использовании нейросетевых моделей [1]. Ядром создаваемой аналитической программной системы является АИС «Бизнес Аналитик», разрабатываемая на кафедре ИСЭ АлтГТУ.

АИС «Бизнес Аналитик» позволяет рассчитывать показатели в модели оценки, при этом возможно использовать три различных решателя: формула, нейронная сеть и экспертная система.

За основу работы создаваемой гибридной экспертной системы будет положена гибридная модель представления знаний экспертов. При построении модели знаний, предоставляемых экспертами и материалами о работе ЖКХ, будет использована древовидная структура знаний как совокупность подзадач, образующих иерархию.

Знания о предметной области, предоставляемые экспертами, являются неструктурированными. Поэтому, во-первых, необходимо выделить функцию цели. Согласно предметной области, основная цель работы управляющей компании жилищно-коммунального хозяйства – обеспечение комфортных условий проживания жильцов многоквартирного дома [2]. Степень обеспечения комфортности достаточно сложно формализовать, хотя бы потому, что «комфортность» является субъективным фактором жизни человека.

Поэтому для построения целевой функции воспользуемся теорией предельной полезности (теорией общественных благ). Исследования опыта экспертов, а также социальный опрос жильцов многоквартирного дома показали, что можно выделить примерно повторяющийся перечень показателей, которые оказывают влияние на степень осуществления комфортности проживания индивида в жилом доме.

Классификация показателей модели оценки представлена на рисунке 1.



Рисунок 1 – Классификация показателей модели оценки деятельности УК




Рисунок 2 – Классификация показателей для оценки оказания жилищных услуг




Рисунок 3 – Классификация показателей для оценки качества работы с собственниками помещений в МКД



Рисунок 4 – Классификация показателей оценки финансового состояния

Нейронные сети являются наиболее универсальным методом, так как для их применения нет необходимости выявлять и доказывать формулы, строить сложную базу правил. Необходимо лишь сформировать достаточную обучающую выборку – задачник и обучить сеть. Впоследствии для улучшения результатов ее можно дообучать и переобучать.

В связи с этим для узла «Оценка оказания жилищных услуг» решателем была выбрана нейронная сеть.

Для формирования обучающей выборки эксперту был предложен ряд вопросов, один из которых предполагал ранжирование показателей от наиболее важного (его значение «1») к наименее важному. Вопрос был сформулирован следующим образом: качество оказания каких услуг, по Вашему мнению, является наиболее и наименее важными. Проранжируйте перечисленные услуги (1-наиболее важная, 7-наименее важная):

- Содержание стен, фасадов, оконных и дверных заполнений;
- Выполнение работ по внешнему благоустройству;
- Выполнение работ по уборке и содержанию жилищного фонда;
- Выполнение работ по уборке придомовой территории;
- Ресурсосбережение, тарифы;
- Обслуживание лифтов;
- Обслуживание мусоропроводов.

При ранжировке объектов в качестве меры согласованности мнений группы экспертов используется дисперсионный коэффициент конкордации (коэффициент согласия). В качестве экспертов были приглашены жильцы многоквартирного жилого дома.

Результаты ранжирования перечисленных показателей группой экспертов из семи человек представлены в таблице 2.

Таблица 2 – Результаты ранжирования показателей

	Э1	Э2	Э3	Э4	Э5	Э6	Э7
Содержание стен, фасадов, оконных и дверных заполнений	3	2	1	2	1	2	3
Выполнение работ по внешнему благоустройству	3	3	1	2	2	2	2
Выполнение работ по уборке и содержанию жилищного фонда	2	4	2	3	3	3	2
Выполнение работ по уборке придомовой территории	2	1	2	1	2	2	2
Ресурсосбережение, тарифы	1	2	3	4	2	1	1
Обслуживание лифтов	2	2	4	1	3	1	2
Обслуживание мусоропроводов.	2	1	2	2	3	3	1

Вычислим коэффициент конкордации и произведем оценку его значимости.

Коэффициент конкордации получился равным $W = 0.12$, что говорит о слабой связанности мнений экспертов. Это можно объяснить высокой субъективностью параметров оценки, а также тем, что эксперты банально живут в разных жилищных условиях – для жильцов последних этажей обслуживание лифтов гораздо важнее, чем первых.

Определим значимость коэффициента конкордации. Для этой цели исчислим критерий согласования Пирсона. Вычисленный χ^2 сравним с табличным значением для числа степеней свободы $K = n-1 = 7-1 = 6$ и при заданном уровне значимости $\alpha = 0.05$. Так как χ^2 расчетный $5.12 <$ табличного (12.59159) , то $W = 0.12$ – величина случайная, а потому полученные результаты имеют смысл и могут использоваться в дальнейших исследованиях.

Поскольку $\chi^2 < \chi^2_{\text{табл}}$, гипотеза о согласии экспертов в ранжировках принимается.

В результате обработки анкет, заполненных экспертами по перечисленным показателям, происходит присваивание целочисленных оценок от 1 до 5. Основываясь на этих данных, был оценен результирующий показатель «Качество оказания жилищных услуг» (шкала оценок: целые числа 1, 2, 3, 4, 5). Была сформирована выборка.

В противоречивых примерах на место итоговой оценки вставлены пропуски (рисунок 5), проанализировав данные примеры, был сделан вывод о том, что есть аномалии – поставлена итоговая оценка 1,2, а так же противоречивые примеры, возможно в этом случае, эксперт при выставлении оценки был невнимателен или повлияли какие-то другие факторы. Удалим данные аномалии и противоречие примеры.




Рисунок 5 – Анализ выборки в программе «Нейро Аналитик»

После устранения аномалий и противоречивых примеров была сформирована новая выборка. Проверим данную выборку на наличие выбросов и аномалий, при загрузке данных, выбросов и аномалий не обнаружено (рисунок 6).




Рисунок 6 – Анализ обработанной выборки в программе «Нейро Аналитик»

Рассмотрим данную выборку на однородность данных. Обучим и протестируем нейронную сеть разной структуры несколько раз методом SCG.

Максимальный разброс ошибок достигается при структуре 1:1 от 0,948 до 0,952, в остальных случаях разброс ошибок намного меньше и во всех случаях он не превышает 5 %, что является допустимым и говорит о том, что выборка однородна.

Для определения структуры нейросети был применен метод конструирования, который предполагает постепенное наращивание структуры. Результаты экспериментов по обучению нейронных сетей различной структуры различными методами (методом сопряженного градиента) представлены на рисунке 7.




Рисунок 7 – Обучение нейросети разной структуры

Литература:

1. Пятковский О.И., Бир А.А. Использование мультиагентных гибридных экспертных систем для оценки деятельности управляющих компаний ЖКХ – Алт. гос. техн.ун-т, Ползуновский Альманах №1, 2014.
2. Брюханова Н.В., Патудин В.М. Управление многоквартирными домами: Учебное пособие / Алт. гос. техн.ун-т.- Барнаул: Изд-во АлтГТУ, 2014. – 240 с.
3. Блюмин И. Г. Эволюция теории «предельной полезности» // Критика буржуазной политической экономии: В 3 томах. – М.: Изд-во АН СССР, 1962. – Т. III. Кризис современной буржуазной политической экономии. – 379 с.
4. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. - Новосибирск: Наука. Сибирская издательская фирма РАН, 1996.
5. Пятковский О.И. Интеллектуальные компоненты автоматизированных информационных систем управления предприятием: Монография / Алт. гос. техн.ун-т.- Барнаул: Изд-во АлтГТУ, 1999.

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В РЕШЕНИИ ЗАДАЧИ КОЛЛЕКТОРСКОГО СКОРИНГА

О.И. Пятковский¹, М.В. Гунер¹

¹Алтайский государственный технический университет им. И.И. Ползунова,
каф. информационных систем в экономике

По данным Центрального банка Российской Федерации, просроченная задолженность россиян по банковским кредитам по состоянию на 1 июня 2015 года составила 747,4 млрд. рублей. С начала 2015 года она выросла на 340,6 млрд. рублей, или более чем на 83%. Помимо макроэкономических проблем России, вызванных падением мировых цен на нефть, одной из основных причин таких значений показателя просроченной задолженности по банковским кредитам является низкая финансовая грамотность российских граждан. Однако и у банков есть стремление к дополнительной прибыли, а отсюда – снижение уровня требований к клиенту. В связи с этим для банков и других кредитных организаций очень важно введение новых моделей оценки платежеспособности [6].

В настоящей работе рассмотрено применение искусственных нейронных сетей в решении задачи коллекторского скоринга. Коллекторский скоринг – это вид скоринга, применяемый для взаимодействия с клиентами, отказывающимися от исполнения условий кредитного договора, т.е. с теми, кто отказывается погашать задолженность. Скоринг в этом случае необходим для определения приоритетности действий служащих коллекторского бюро при работе по возвращению «плохого» кредита.

Использованная далее выборка с реальной информацией о банковских займах, проданных коллекторским агентствам, была загружена с официального сайта международной платформы датамайнинга AlgoMost (algomost.com) в рамках участия в конкурсе, объявленном ей совместно с компанией SAS Россия/СНГ, «Соревнования SAS Russia по анализу данных: коллекторский скоринг», направленном на создание аналитической модели для оценки платежеспособности заемщика и прогнозирования выплат по задолженности [5].

Всего в загруженной выборке содержится порядка 6200 примеров, фрагмент выборки представлен в таблице 1. Для каждого займа даны характеристики и информация о заемщике – всего 20 исходных показателей, в том числе финансовая информация и обезличенные социально-демографические данные. Задача – оценить платежеспособность заемщика и спрогнозировать, как он будет производить выплаты по долгу.

Ввиду того, что алгоритмическое решение поставленной задачи отсутствует, а количество входных параметров велико и исходные данные отличаются неполнотой, противоречивостью и неоднозначностью, коллекторский скоринг относится к классу сложных слабоформализуемых задач, с которыми вполне успешно при наличии достаточного статистического материала справляются искусственные нейронные сети [1, 4].

Прежде чем непосредственно приступить к обучению нейронных сетей, необходимо выполнить анализ и предобработку исходных данных: выявить и устранить аномальные значения и пропуски, закодировать качественные параметры, нормировать и масштабировать все входы. В нашем случае аномальные значения были откорректированы при помощи методов фильтрации, пропущенные значения восстановлены при помощи методов интерполяции либо полностью исключены из обработки [2, 3].

Таблица 1

Фрагмент исходной выборки с реальной информацией о банковских займах, проданных коллекторским агентствам, и отметкой о погашении (либо отсутствии погашения) заемщиками своих задолженностей

Программа кредитования	Дата рождения заемщика	Пол	Населенный пункт фактического проживания заемщика	Тип населенного пункта	Дата выдачи кредита	Тип залога	Индикатор наличия телефона для связи	Дата окончания кредита по договору	Дата выхода на просрочку	Дата последней оплаты	Размер кредита, выраженный в рублях	Размер ежемесячного платежа, выраженный в рублях	Срок кредита в месяцах по договору	Головная процентная ставка по договору	Количество поручителей	Остаток основного долга в рублях	Начисленные проценты в рублях	Сумма начисленных штрафов, комиссий и прочих начислений в рублях	Тип безисходности	Оценка (1 - хор., 0 - плох.)
АВТОКРЕДИТ	20.03.1964	М	Черногорск	г	08.05.07	залог ипот.	Да	08.05.12	17.03.11	10.02.12	252000	4968,75	60	10	0	33316,76	1860,23	22796,47	-	0
АВТОКРЕДИТ	11.08.1965	Ж	Абакан	г	24.06.07	залог ипот.	Да	24.06.12	01.04.11	16.10.11	85000	2168,98	60	10	0	18670,72	1251,28	9112,97	-	0
АВТОКРЕДИТ	09.12.1977	М	Абакан	г	17.06.07	залог ипот.	Да	17.06.12	25.06.11	17.11.11	296775	7493,1	60	10	1	64057,82	3366,43	12093,85	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	14.03.1974	М	Белово	г	22.05.09	-	Да	22.05.15	30.08.11	19.07.11	56309	1769	72	32	0	38672,41	13605,83	0	-	0
АВТОКРЕДИТ	11.10.1978	Ж	Нефтегоганск	г	22.09.08	-	Да	22.09.13	30.07.11	22.06.11	253203	4185	60	13	0	99862	14029,56	0	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	16.12.1980	М	Чулым	г	02.06.09	-	Да	02.06.15	10.09.11	15.08.11	36158	975	72	25	0	27791,75	7872,2	0	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	20.12.1977	Ж	Заозерный	г	23.06.08	-	Да	28.05.13	01.10.09	17.01.13	110000	4263	59	40	0	92294,18	83940,53	28950,49	-	1
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	25.01.1984	Ж	Минусинск	г	27.07.07	-	Да	27.07.12	04.06.11	29.08.11	312000	8101	60	19	1	98517,56	14425,18	3738,43	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	13.10.1977	М	Полевской	г	09.09.08	залог ипот.	Да	08.10.13	16.04.11	30.03.11	234457	6081,94	61	19	0	146767,74	34682,01	0	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	17.11.1981	М	Екатеринбург	г	10.09.08	залог ипот.	Да	05.10.13	21.01.11	28.12.11	303935	7717,95	61	18	0	143735,81	19129,04	0	-	0
АВТОКРЕДИТ	02.01.1950	Ж	Агинское	пгт	19.06.07	-	Да	19.06.12	28.06.11	10.06.11	53500	1418	60	20	0	16383,94	1986,54	11823,5	-	1
АВТОКРЕДИТ	14.03.1968	М	Косеньская	ст	04.09.07	-	-	04.09.12	12.07.11	18.01.12	13937	339	60	16	0	4361,11	502,94	5017,44	-	0
ПОТРЕБИТЕЛЬСКИЙ КРЕДИТ	04.09.1972	М	Краснокаменск	г	25.06.07	-	Да	25.06.12	05.05.09	16.02.10	260520	5409	60	9	1	177359,18	29962,9	67389,84	смерть	0
АВТОКРЕДИТ	19.12.1969	Ж	Балей	г	04.09.07	-	Да	04.09.12	12.05.11	28.06.11	53500	1301	60	16	0	17565,81	3515,64	18292,55	-	0

Более подробно рассмотрим процедуру кодирования качественных параметров. В исходной выборке имеются как двузначные, так и многозначные номинальные переменные. Двузначную номинальную переменную легко преобразовать в числовую, например, пол: мужской пол – 1, женский пол – 0.

Сложности возникают при кодировании многозначной номинальной переменной, например, программы кредитования. Если её представить одним числовым значением, то может возникнуть ложное упорядочивание значений номинальной переменной (например, потребительский кредит может оказаться чем-то средним между автокредитом и экспресс-кредитом). Отличным решением здесь будет являться так называемое кодирование 1-из-N, в котором одна номинальная переменная представляется несколькими числовыми переменными, при этом количество числовых переменных равно числу возможных значений номинальной переменной, и всякий раз ровно одна из N переменных принимает ненулевое значение [8] (см. таблицу 2).

Таблица 2
Кодирование номинальных переменных

Наименование параметра	Значения номинальной переменной	Кодированные значения переменной											
Пол	М (Мужской)	1											
	Ж (Женский)	0											
Индикатор наличия телефона для связи с заемщиком	Да	1											
	- (Нет)	0											
Тип залога	Залог имущества	1											
	- (Нет)	0											
Тип безысходности	Смерть заемщика	1											
	- (Нет)	0											
Оценка платежеспособности и заемщика	Хор. (заемщик производит выплаты по долгу)	1											
	Плох. (заемщик не производит выплаты по долгу)	0											
Программа кредитования	Автокредит	0	0	0	0	0	0	0	0	0	0	1	
	Потребительский кредит	0	0	0	0	0	0	0	1	0	0	0	
	Экспресс-кредит	0	0	0	1	0	0	0	0	0	0	0	
	Кредитная карта овердрафт	0	0	1	0	0	0	0	0	0	0	0	
	Кредит для малого и среднего бизнеса	0	1	0	0	0	0	0	0	0	0	0	
	Иное	1	0	0	0	0	0	0	0	0	0	0	
Тип населенного пункта (фактического проживания заемщика)	г (город)	0	0	0	0	0	0	0	0	0	0	1	
	д (деревня)	0	0	0	0	0	0	0	0	0	1	0	
	жилрайон (жилой район)	0	0	0	0	0	0	0	0	1	0	0	
	мкр (микрорайон)	0	0	0	0	0	0	1	0	0	0	0	
	п (поселок)	0	0	0	0	0	1	0	0	0	0	0	
	п/р (планировочный район)	0	0	0	0	1	0	0	0	0	0	0	
	пгт (поселок городского типа)	0	0	0	1	0	0	0	0	0	0	0	
	рп (рабочий поселок)	0	0	1	0	0	0	0	0	0	0	0	

	с (село)	0	0	1	0	0	0	0	0	0	0	0	
	ст (станция)	0	1	0	0	0	0	0	0	0	0	0	
	ст-ца (станция)	1	0	0	0	0	0	0	0	0	0	0	

К сожалению, при большом числе возможных значений номинальной переменной, например, города фактического проживания заемщика (см. рис. 1), метод кодирования 1-из-N потребует большого количества числовых переменных, а это приведет к росту размеров нейронной сети и создаст трудности при ее обучении. В связи с этим было принято решение заменить входной параметр «Населенный пункт фактического проживания заемщика» на несколько числовых социально-экономических показателей соответствующего населенного пункта:

- численность населения (величина численности населения, деленная на 100 тыс. чел. и округленная до ближайшего целого в меньшую сторону);
- уровень безработицы (численность безработных граждан, зарегистрированных в государственных учреждениях службы занятости, к общей численности трудоспособного населения, в процентах);
- среднемесячная номинальная начисленная заработная плата (номер кластера; выделенные 12 кластеров с различными диапазонами уровня зарплат приведены в таблице 4);
- признак «является столицей субъекта РФ» (1 – да, 0 – нет).

Социально-экономические показатели свыше 160 крупных городов России были взяты с официального сайта Федеральной службы государственной статистики [7]. Показатели по Сибирскому федеральному округу приведены в таблице 3.




Рис. 1. Статистические данные выборки. Распределение заемщиков по городу фактического проживания

Таблица 3

Социально-экономические показатели крупных* городов Сибирского федерального округа (статистические данные приведены на конец 2013 г.)

Название города	Численность населения, тыс. чел.	Численность трудоспособного населения (мужчины 16-59 лет, женщины 16-54 года), тыс. чел.	Численность безработных граждан, зарегистрированных в государственных учреждениях службы занятости		Среднемесячная номинальная начисленная заработная плата, руб.	Является столицей субъекта РФ	Название субъекта РФ
			чел.	% от численности трудоспособного населения			
Барнаул	695,7	433,2	1492	0,34	24 449,40	Да	Алтайский кр.
Бийск	213,7	124,7	1050	0,84	19 558,20		Алтайский кр.
Рубцовск	147,4	86,7	560	0,65	18 918,90		Алтайский кр.
Чита	335,8	213,5	1365	0,64	34 478,20	Да	Забайкальский кр.
Иркутск	613,0	383,9	1447	0,38	37 216,20	Да	Иркутская обл.
Ангарск	229,6	136,1	508	0,37	33 359,40		Иркутская обл.
Братск	238,8	141,9	898	0,63	33 651,40		Иркутская обл.
Кемерово	544,0	334,9	2741	0,82	31 544,00	Да	Кемеровская обл.
Белово	130,7	74,2	795	1,07	28 017,50		Кемеровская обл.
Ленинск-Кузнецкий	101,5	57,4	849	1,48	26 734,20		Кемеровская обл.
Междуреченск	101,0	59,0	998	1,69	33 416,60		Кемеровская обл.
Новокузнецк	550,2	328,0	2550	0,78	28 980,40		Кемеровская обл.
Прокопьевск	202,7	113,1	2324	2,05	22 554,60		Кемеровская обл.
Красноярск	1036,6	672,0	2300	0,34	35 874,50	Да	Красноярский кр.
Ачинск	107,8	63,6	474	0,75	25 847,80		Красноярский кр.
Норильск	177,3	126,1	1094	0,87	66 584,10		Красноярский кр.
Новосибирск	1547,9	965,5	4570	0,47	33 040,00	Да	Новосибирская обл.
Бердск	101,7	60,1	717	1,19	24 782,00		Новосибирская обл.
Омск	1166,1	719,9	1889	0,26	28 064,00	Да	Омская обл.
Горно-Алтайск	61,4	37,8	547	1,45	29 298,90	Да	Респ. Алтай
Улан-Удэ	421,5	262,0	2145	0,82	30 629,30	Да	Респ. Бурятия
Кызыл	114,0	72,1	771	1,07	35 010,60	Да	Респ. Тыва
Абакан	173,2	106,9	909	0,85	33 152,90	Да	Респ. Хакасия
Томск	578,6	375,4	1443	0,38	34 347,00	Да	Томская обл.

* Крупные города – города с численностью населения свыше 100 тыс. чел. либо являющиеся столицей субъекта РФ.

При формировании обучающей выборки для городов и населенных пунктов с численностью населения менее 100 тыс. чел. и по которым в ежегодно выпускаемом справочнике Федеральной службы государственной статистики отсутствовали данные использовались средние значения по стране (либо по федеральному округу) с учетом вида поселения. Так уровень безработицы на конец 2013 года в среднем по стране составил 5,6%, причем среди городского населения – 4,7% и среди сельского населения – 8,3%.

Как видно из пузырьковой диаграммы распределения крупных городов по численности населения (см. рис. 2), уровню безработицы и среднемесячной номинальной начисленной заработной плате, в городах с численностью населения свыше 1 млн. чел. уровень официальной безработицы на конец 2013 года не превышал 1%, уровень заработной платы в среднем колебался от 25 до 40 тыс. руб. В городах с численностью населения менее 500 тыс. чел. разброс уровня безработицы и заработной платы оказался куда более значителен.




Рис. 2. Пузырьковая диаграмма «Распределение крупных городов России по численности населения, уровню безработицы и среднемесячной номинальной начисленной заработной плате»

Таблица 4

Выделенные кластеры населенных пунктов по уровню среднемесячной номинальной начисленной заработной платы

№ кластера	Диапазон уровня зарплаты, тыс. руб.	Населенные пункты, вошедшие в составе кластера
Кластер 1	Свыше 70 000	Анадырь, Новый Уренгой, Салехард
Кластер 2	65 000 – 69 999	Сургут, Норильск
Кластер 3	60 000 – 64 999	Южно-Сахалинск, Ханты-Мансийск, Ноябрьск, Нарьян-Мар, Магадан
Кластер 4	55 000 – 59 999	Петропавловск-Камчатский, Москва
Кластер 5	50 000 – 54 999	Нижневартовск, Нефтеюганск, Якутск
Кластер 6	45 000 – 49 999	Домодедово, Ухта, Мурманск, Королев
Кластер 7	40 000 – 44 999	Красногорск, Хабаровск, Жуковский, Балашиха, Мытищи, Люберцы, Тюмень
Кластер 8	35 000 – 39 999	Владивосток, Екатеринбург, Иркутск, Северодвинск, Санкт-Петербург, Железнодорожный, Череповец, Сочи, Сыктывкар, Находка, Красноярск, Архангельск, Тобольск, Обнинск, Кызыл
Кластер 9	30 000 – 34 999	Чита, Краснодар, Благовещенск, Томск, Комсомольск-на-Амуре, Братск, Коломна, Междуреченск, Ангарск, Артем, Петрозаводск, Абакан, Новосибирск, Пермь, Новороссийск, Альметьевск, Уфа, Нижний Новгород, Ногинск, Ростов-на-Дону, Кемерово, Калуга, Биробиджан, Магнитогорск, Улан-Удэ, Уссурийск
Кластер 10	25 000 – 29 999	Калининград, Казань, Великий Новгород, Самара, Тверь, Горно-Алтайск, Челябинск, Вологда, Новокуйбышевск, Ярославль, Тула, Березники, Новокузнецк, Нижнекамск, Омск, Белово, Липецк, Оренбург, Астрахань, Рязань, Салават, Воронеж, Ставрополь, Ленинск-Кузнецкий, Новомосковск, Белгород, Первоуральск, Волгоград, Миасс, Волгодонск, Пятигорск, Ижевск, Саратов, Тольятти, Набережные Челны, Ачинск, Магас, Владимир, Киров, Грозный, Псков, Старый Оскол, Махачкала, Смоленск
Кластер 11	20 000 – 24 999	Октябрьский, Бердск, Курган, Невинномысск, Батайск, Пенза, Барнаул, Брянск, Иваново, Орел, Ковров, Кострома, Назрань, Курск, Копейск, Чебоксары, Владикавказ, Новочеркасск, Рыбинск, Ульяновск, Стерлитамак, Дзержинск, Нальчик, Эссентуки, Волжский, Тамбов, Таганрог, Прокопьевск, Кисловодск, Нефтекамск, Майкоп, Йошкар-Ола, Черкесск, Сызрань, Энгельс, Златоуст, Элиста, Саранск, Балаково, Муром, Дмитровград, Армавир, Новочебоксарск, Арзамас, Елец, Орск
Кластер 12	Менее 19 999	Шахты, Бийск, Рубцовск, Хасавюрт, Новошахтинск, Каспийск, Дербент и другие населенные пункты

Кроме числовых и строковых реквизитов в исходной выборке также содержались поля типа «дата»: дата рождения заемщика, дата выдачи кредита, дата окончания кредита по договору, дата выхода на просрочку и дата последнего платежа. На основе этих данных были рассчитаны и включены в новую выборку следующие показатели: возраст заемщика на момент взятия кредита, количество прошедших дней с даты выдачи кредита по дату выхода на просрочку и количество прошедших дней с даты последнего платежа по максимальную дату в этом же столбце - 23.01.2013.

Особое внимание было уделено проблеме обеспечения сбалансированности набора данных: данные разных классов должны быть представлены в обучающей выборке примерно в одинаковых долях.

В качестве типа искусственной нейронной сети был выбран многослойный персептрон. Обучение производилось в среде Deductor. Результаты вычислительных экспериментов по определению оптимальной структуры нейросети приведены на рис. 3. Наилучший результат показал персептрон с двумя скрытыми слоями, на каждом из которых по два нейрона, ошибка обобщения минимальна и составила 0,241. Правильно распознано около 70% примеров. Проведенные эксперименты показали целесообразность использования нейронных сетей для решения задачи классификации заемщиков, однако над эффективностью распознавания примеров еще стоит работать.

Еще одной особенностью рассматриваемой задачи является необходимость учета так называемых издержек ошибок классификации того или иного рода. Закономерен вопрос: что будет меньшим злом – принятие благонадежного заемщика за неблагонадежного (ошибка первого рода, или ложное срабатывание) или принятие неблагонадежного заемщика за благонадежного (ошибка второго рода, или пропуск события). В нашем случае очевидно, что менее затратны ошибки первого рода, поэтому создаваемая модель должна обладать высокой чувствительностью, т.е. лучше принять благонадежного заемщика за неблагонадежного, чем пропустить «злостного» неплательщика.




Рис. 3. Разброс средних ошибок обучения и обобщения
в зависимости от структуры нейронной сети

С целью подбора оптимальных параметров чувствительности модели была построена таблица 5, содержащая сведения о количестве правильно распознанных хороших и плохих заемщиков в зависимости от правила округления ответа нейронной сети. Будем считать, что ответ нейронной сети есть оценка вероятности того, что заемщик благонадежный.

Таблица 5

Сведения о количестве правильно распознанных примеров
в зависимости от правила округления

Правило округления	Распознано примеров (выход 0 – плох. заемщик), %	Распознано примеров (выход 1 – хор. заемщик), %
0,5	73,47	64,26
0,6	87,27	42,72
0,7	97,41	22,26
0,8	98,5	17,3
0,9	99,25	12,13

В перспективе планируется провести эксперименты по обучению на основе этих же данных нечетких нейронных сетей, а также нейронных сетей, реализованных в пакете MatLab, после чего сравнить результаты.

Список литературы

1. Горбань А.Н. Обучение нейронных сетей / А.Н. Горбань. - М.: изд. СССР-США СП "ParaGraph", 1990. - 159с.
2. Матвеев, М.Г. Модели и методы искусственного интеллекта. Применение в экономике: учебное пособие / М.Г. Матвеев, А.С. Свиридов, Н.А. Алейникова. - М.: Финансы и статистика, ИНФРА-М, 2008. - 448с.: ил.
3. Миркес Е.М. Нейрокомпьютер. Проект стандарта / Е.М. Миркес. - Новосибирск: Наука. Сибирское предприятие РАН, 1999. - 337с.
4. Пятковский О.И. Интеллектуальные компоненты автоматизированных информационных систем управления предприятием: Монография / О.И. Пятковский. - Барнаул: изд-во АлтГТУ, 1999. - 351с.
5. SAS и AlgoMost запустили конкурс для специалистов по анализу данных и бизнес-аналитиков // Фонд Сколково [Электронный ресурс]. – URL: <http://sk.ru/news/b/news/archive/2014/09/29/sas-i-algomost-zapustili-konkurs-dlya-specialistov-po-analizu-dannyh-i-biznesanalitikov.aspx> - Загл. с экрана.
6. Обзор банковского сектора Российской Федерации (интернет-версия). Аналитические показатели № 155 (2015) // Центральный банк Российской Федерации [Электронный ресурс]. – URL: http://www.cbr.ru/analytics/bank_system/obs_ex.pdf - Загл. с экрана.
7. Регионы России. Основные социально-экономические показатели городов (2014) // Федеральная служба государственной статистики [Электронный ресурс]. – URL: http://www.gks.ru/free_doc/doc_2014/region/town.rar - Загл. с экрана.
8. Электронный учебник по статистике. Нейронные сети // StatSoft [Электронный ресурс]. – URL: <http://www.statsoft.ru/home/textbook/modules/stneunet.html> - Загл. с экрана.

ВЛИЯНИЕ СЕКСУАЛЬНОСТИ ВИЗУАЛЬНЫХ ОБРАЗОВ В РЕКЛАМЕ НА ЕЁ КОГНИТИВНУЮ ЭФФЕКТИВНОСТЬ

М.Г. Садовский², М.С. Иванова¹

¹ Сибирский федеральный университет, институт архитектуры и дизайна,
ianimei@mail.ru

² Институт вычислительного моделирования Сибирского отделения Российской
академии наук, *msad@icm.krasn.ru*

Введение

В последнее десятилетие реклама из чисто функционального явления для привлечения покупателей превратилась в настоящее искусство, сродни кино и фотографии. В современном обществе реклама определяет значимое культурное пространство. Можно говорить о том, что реклама является одним из факторов, определяющих поведение и мышление. Рекламная коммуникация обладает собственным специфическим языком, в том числе и в рекламе отдельных товарных категорий. Понимание этого языка и особенностей его восприятия значительно повышает возможности эффективного управления рекламной кампанией в целом. И чем искусней сделана реклама, тем сильнее она имеет влияние на потребителя.

Для современной рекламы, характерно присутствие гендерных стереотипов, она постоянно опирается на образы мужчины и женщины, существующие у большинства реципиентов. Зачастую от таких образов и стереотипов зависит все наше окружение и внешняя среда. Социальные психологи считают, что две основные причины, из-за которых люди стараются соответствовать гендерным стереотипам, — это нормативное и информационное давление. Термин *нормативное давление* описывает механизм того, как человек вынужден подстраиваться под общественные или групповые ожидания, чтобы общество не отвергло его. Информационное давление вызвано тем, что, расширяя знания о себе и о мире, стремясь понять, какой позиции следует придерживаться в тех или иных социальных вопросах, человек в большей степени опирается не на собственный опыт, а на информацию, предоставляемую окружающими. «Когда мы смотрим вокруг и видим, как мужчина и женщина делают разные вещи, и слышим, как окружающие нас люди и средства массовой информации подчеркивают, насколько велика разница между мужчинами и женщинами, мы приходим к выводу, что так и есть на самом деле, и соответствуем этим ожиданиям. Убеждение, что гендеры должны обладать и обладают массой отличий, настолько повсеместно укрепились в нашей культуре, что неудивительно, если мы считаем его верным.» [1].

Однако всё большее число учёных соглашается с представителями новой психологии пола [4, 5], которые считают, что основную роль в формировании психического пола и гендерной роли играют социальные ожидания общества, которые возникают в соответствии с конкретной социально-культурной матрицей и находят свое отражение в процессе воспитания. Причём пол психический, социальный, который усваивается прижизненно, играет большую роль, чем пол биологический.

Поскольку одним из критериев построения рекламного сообщения являются различия в гендерном восприятии [1], постольку реклама, ориентированная на мужскую и женскую аудитории, должна отличаться по своей направленности [3]. Показано, что мужчины и женщины по разному относятся к сексу как социальному явлению, что обусловлено биологическими и психологическими различиями полов, которые зачастую значительно глубже, чем вторичное влияние культуры.

В работе [5] показано, что женщинам не нравится:

- 1) откровенная демонстрация обнаженного тела;
- 2) образ независимой бизнес-леди или женщины, не имеющей сексуального партнера;
- 3) если им отводится роль сексуального объекта.

Всё вышесказанное позволяет рассматривать рекламу женской парфюмерии как социально важный феномен, поскольку реклама в этом сегменте продуктов в основном имеет как раз сексуальный подтекст. Товар, ориентированный на женскую аудиторию, рекламируют полуобнаженные, обнаженные либо раздевающиеся в кадре девушки и женщины.

Цель настоящей работы — дать предварительный анализ изложенной выше проблемы и проанализировать воздействие эротики в рекламе женской парфюмерии на целевую аудиторию. Традиционно используемый рекламоноситель в категории дорогой парфюмерии — глянцевые журналы. Другие виды рекламы, как телевизионная и радиореклама, наружная реклама используются реже. Также печатные изображения легче в тестировании, поэтому в данной работе стимульный материал будет представлен печатной рекламой женской парфюмерии.

Объектом исследования являются гендерные особенности восприятия рекламы женщинами от 17 до 28 лет. Анализ данной проблемы показал, какие именно рекламные стереотипы не работают, а какие наиболее эффективны для женской целевой аудитории. Практическое применение полученных результатов возможно для рекламных агентств, разработчиков рекламы, как ориентир для воспроизведения в рекламе характеристик необходимых женскому рекламному образу в данной категории товаров.

Разработка стимульного материала

Для отбора стимульного материала был проанализирован значительный массив визуальных образов представленных в рекламе женской парфюмерии, для выделения того образа женщины, который отталкивает либо напротив, привлекает потребителя. Для этого использовались печатные издания Cosmopolitan, Elle и Vogue с 2009 по 2014. Критерием отбора журнала служил наибольший процент размещения печатной рекламы женской парфюмерии.

Существует несколько оснований для выделения классификаций типов рекламных женских образов (см., например, [2]):

- 1) образ сексуальной женщины;
- 2) образ независимой женщины;
- 3) образ женщины домохозяйки.

В работе [2] высказано предположение, что женские образы делятся по соответствующим основным стереотипным ценностям на образы, используемые в рекламе для женской аудитории и образы, используемые в рекламе для мужской аудитории. В рекламе для женской аудитории эксплуатируются следующие женские образы:

- 1) образ матери и жены (хранительница домашнего очага);
- 2) образ беззаботной красавицы;
- 3) образ бизнес-леди.

В рекламе для мужской аудитории используются следующие женские образы:

- 1) образ сексуальной женщины;
- 2) образ легкомысленной женщины;
- 3) образ любимой женщины.

Аналогично, Дж. Килбурн [4] считает, что самые распространённые женские образы в рекламе — это домохозяйка и женщина как сексуальный объект: новый образ, который выделяет Дж. Килбурн, это образ пассивной женщины-ребенка.

На основе проанализированных классификаций женских образов, а также на основе анализа рекламных материалов, была составлена обобщенная классификация женских образов, наиболее часто встречающихся в рекламе женской парфюмерии.

Таблица 1

Классификация женских образов в рекламе парфюмерии

Название женского образа	Характеристики
«Влюбленная» женщина	верность, великодушие, заботливость, замкнутость, обособленность
«Самодостаточная» женщина	независимость, самодостаточность, активность, практицизм, интеллектуальность
«Соблазняющая» женщина	игривость, сексуальность, чувственность, обаяние, притягательность
«Легкомысленная» женщина	зависимость, пассивность, легкомыслие, необязательность, инфантильность

Из списка женских образов, ключевую роль для данной работы играет образ «соблазняющей» женщины. На начальной стадии подготовки к экспериментам была собрана коллекция образцов рекламы женской парфюмерии. Из собрания более чем в 1000 экземпляров были выделены 20 изображений для последующего использования.

Отбор стимульного материала из собрания проходил в несколько этапов. На первом этапе из коллекции были убраны откровенные изображения с оголёнными интимными местами. На втором — изображения с парами. Затем испытуемым — девушкам 17 – 28 лет — было предложено отобрать изображения, основываясь на своем представлении о сексуальности модели на рекламном плакате. Окончательный стимульный материал был сформирован из наиболее повторяющихся отобранных фотографий женской группой респондентов.

Отобранный материал был разбит на 2 группы по 10 изображений. Деление основывалось на базовых знаковых элементах рекламы. В данной статье представлены 4 типичных изображения для той или иной выборки.

Таблица 2.

Реклама с явной сексуальной направленностью
(характеристики: сексуальность, чувственность, томность, порочность)



Таблица 3.
Реклама с намеком на сексуальность
(характеристики: игривость, обаяние, притягательность)



Для более объективной оценки изображения материалы тестирования были обработаны в графическом редакторе Adobe Photoshop (с фотографий был удален рекламируемый продукт).

Таблица 4.
Обработка в графическом редакторе Adobe Photoshop.



Отбор стимульного материала для проведения глубинного интервью проходил при помощи устного опроса 30-ти испытуемых. Опрашиваемые являлись потенциальными потребителями женской парфюмерии. Девушкам было предложено выбрать из колоды изображений в 20 карточек, изображения на их взгляд самые сексуальные и сексуально завуалированные. По итогам опроса были отобраны 4 изображения, по 2 в каждой группе, с наибольшим количеством голосов.



После было проведено глубинное интервью с десятью потенциальными покупателями парфюмерии. Респондентам поочередно выдавались отобранные изображения и далее по каждому из них был задан ряд вопросов.

Опросник, использовавшийся для проведения глубинного интервью.

- 1) Охарактеризуйте представленное изображение.
- 2) Как вы думаете, что может рекламировать данное изображение?
- 3) Ваше впечатление от увиденного изображения?
- 4) Что вы можете сказать о девушке изображенной на фотокарточке?
- 5) Какие эмоции у вас вызывает эта фотокарточка?
- 6) Что вы можете сказать об этом изображении?

Из полученных ответов были выделены существительные и прилагательные, наиболее ярко характеризующие изображения.

Таблица 5.

Список слов ярко характеризующих изображения.

Агрессивный	Болезненный	Безжизненный	Зависимый	Дикий
Аккуратный/ухаженный	Гармоничный	Опасный	Хрупкий	Яркий
Естественный/настоящий	Бездушный	Вредный	Постоянный	Свет
Умиротворение	Грубый	Беспокойный	Обычный	Зло
Симпатия	Простой	Настороженный	Порочный	Идеал
Отталкивающий	Добродетель	Обычный	Бедность	Доверие

Далее к отобранным словам были подобраны полярные понятия (антонимы).

Таблица 6.

Полярные пары слов характеризующих изображения.

Вредный — безопасный	Бездушный — чуткий	Простой — замысловатый
Хрупкий — основательный	Порочный — невинный	Опасный — притягательный
Отталкивающий — приятный	Свет — тьма	Естественный — искусственный
Безжизненный — жизнерадостный	Болезненный — здоровый	Беспокойный — умиротворенный
Ухоженный — неопрятный	Возвышенный — низкий	Агрессивный — миролюбивый
Послушный — строптивый	Обычный — сказочный	Умиротворение — дисгармония
Настороженный — умиротворенный	Симпатия — отторжение	Гармоничный — беспорядочный
Бедность — обеспеченность	Зло — добро	

Из имеющегося списка полярных слов характеризующих изображение были отобраны пары для проведения исследования методом семантического дифференциала (так называемые полярные шкалы, по Осгуду). Пары слов отождествляли

- 1) отношение: *опасный — доверительный, естественный — искусственный*;
- 2) идентификацию: *идеал — несовершенство, отталкивающий — приятный*;
- 3) настроение: *яркий — неприметный/тусклый, безжизненный — живой/жизнерадостный*.


Также в анкету были включены парные слова, характеризующие изображения, как открыто сексуальные либо сексуально завуалированные:


- 4) сексуальность изображения: *чувственный — неэмоциональный, порочный — невинный*;
- 5) скрытая сексуальность: *игривый — серьезный, притягательно — безразлично*.

Результаты и обсуждение

Результаты исследования экспериментальной группы А, показывают восприятие сексуальности в изображениях, использующих женские образы.

Таблица 7.
Восприятие образа 20-ти совмещенных изображений.

А – оценка сексуальности, В – оценка завуалированной сексуальности		
Изображение №7 А – 8; В – 13 	Изображение №11 А – 2; В – 19 	Изображение №1 А – 19; В – 2 
Изображение №2 А – 20; В – 1 	Изображение №12 А – 6; В – 15 	Изображение №9 А – 14; В – 6 
Изображение №6 А – 13; В – 8 	Изображение №13 А – 0; В – 21 	Изображение №3 А – 14; В – 7 

Изображение №4 А – 2; В – 19 	Изображение №14 А – 7; В – 14 	Изображение №8 А – 3; В – 18 
Изображение №16 А – 0; В – 21 	Изображение №5 А – 16; В – 5 	Изображение №15 А – 0; В – 21 
Изображение №20 А – 2; В – 19 	Изображение №17 А – 0; В – 21 	Изображение №10 А – 13; В – 8 

На основе всего обработанного материала была составлена ментальная карта «Семиотическая структура образа «соблазняющая» женщина в печатной рекламе женской парфюмерии» подобранных характерных знаковых категорий, для разделения образа «Соблазняющая» женщина, для последующего применения при разработке рекламы.

Таблица 8.
Семиотическая структура образа «соблазняющая» женщина
в печатной рекламе женской парфюмерии

Образ «соблазняющая» женщина				
персонажи	поза	лицо	внешний вид	цвета изображения, фон
Реклама с явной сексуальной направленностью				
стильная самоуверенная девушка	динамичная либо статичная, в кадре изображение по пояс или только лицо	серьезное выражение лица приоткрытый рот, магнетический взгляд	частичная обнаженность или полная, растрепанные волосы	одно- или двухцветное изображение. Цвета темные
роковая женщина	изображена стоя, но с готовностью к действию. Акцент на физической привлекательности	серьезное выражение лица, прямой призывный взгляд	сексуальное платье или белье, яркий макияж	

чувственная женщина	статичность — героиня лежит или сидит в расслабленной соблазнительной позе	серьезное, выражение глаза чуть закрыты, взгляд с «поволокой»	частичная обнаженность	темные цвета в качестве фона - элементы роскоши или красивый пейзаж
Реклама с намеком на сексуальность				
молодая девушка	статичность, анфас, показаны в большей степени лицо и плечи	легкая улыбка, прямой открытый взгляд	распущенные волосы, манерность в позе	пастельные, нейтральные оттенки, прозрачность
счастливая женщина	статичная поза. Изображена лежа, или 3/4 в естественной позе, расслаблена	спокойная улыбка либо счастливый смех, счастливый взгляд, зрительный контакт	естественная обнаженность или повседневная одежда	комбинация телесных цветов и темного фона, также яркие цвета
женщина с выраженной индивидуальностью	статичность, закрытая поза, анфас	серьезность, прямой независимый взгляд	полностью одета	гармоничный фон

Анализ проводился в двух направлениях: реклама с явной сексуальной направленностью и реклама с намеком на сексуальность. Были проанализированы персонажи, поза, лицо, внешний вид и цвета, изображение фон. После этого в каждом направлении были обобщены характерные знаковые категории и выделены основные черты. Результаты позволяют полнее оценить особенности организации знаковой системы сообщений, а также представить возможное структурирование всего пространства рекламных посланий с данным образом, которое было использовано для составления стимульного материала.

Полностью соответствуют разработанной типологии 60 % проанализированных рекламных образцов, около 30 % образцов представляют собой смешанные типы. 10 % не поддаются описанию в рамках предложенной типологии.

После эксперимент продолжился в двух экспериментальных группах В и С.


Таблица 9.

Кодировка сокращений анкет группы В и С

доверительный - настоящий	д/н	идеал – притягательный	ид./п	яркий – жизнерадостный	я/ж
опасный - искусственный	о/и	несовершенство – отталкивающий	нес./от.	неприметный – безжизненный	неп./б

В группе В проводилось тестирование по изображениям сексуального характера. Респондентам необходимо было дать оценку представленным образам по шести характеристикам. Данные характеристики отождествляли собой: отношение к образу, идентификация и настроение восприятия.

Таблица 10 – Данные тестирования по изображениям сексуального характера группы В.

оценка	№ изоб.		отношение к образу		идентификация		настроение восприятия	
[+]	1	д/н	50	ид./п	50	я/ж	44	
[-]		о/и	20	нес./от.	17	неп./б	20	
[+]	2	д/н	24	ид./п	39	я/ж	43	
[-]		о/и	58	нес./от.	40	неп./б	0	
[+]	3	д/н	47	ид./п	61	я/ж	79	
[-]		о/и	32	нес./от.	14	неп./б	5	
[+]	4	д/н	93	ид./ п	70	я/ж	68	
[-]		о/и	7	нес./от.	7	неп./б	16	
[+]	5	д/н	27	ид./п	51	я/ ж	70	
[-]		о/и	48	нес./от.	16	неп./б	11	
[+]	6	д/н	17	ид./п	52	я/ж	47	
[-]		о/и	61	нес./от.	22	неп./б	20	
[+]	7	д/ н	55	ид./ п	72	я/ ж	60	
[-]		о/и	34	нес./от.	11	неп./б	14	

[+]	8	д/н	14	ид./п	34	я/ж	36	
[-]		о/и	47	нес./от.	48	неп./б	52	
[+]	9	д/н	88	ид./п	90	я/ж	63	
[-]		о/и	14	нес./от.	10	неп./б	16	
[+]	10	д/н	46	ид./п	35	я/ж	15	
[-]		о/и	26	нес./от.	22	неп./б	56	

Данные в таблице представляют сумму баллов отрицательной или положительной оценки по каждому изображению. Сумма баллов бралась по модулю.

Таблица 11.
Оценка сексуальности изображения

	№ изоб.		сексуальность изображения		№ изоб.		сексуальность изображения
[+]	1	неэмоциональный – невинный	18	[+]	6	неэмоциональный – невинный	7
[-]		чувственный - порочный	59	[-]		чувственный - порочный	74
[+]	2	неэмоциональный – невинный	6	[+]	7	неэмоциональный – невинный	13
[-]		чувственный - порочный	114	[-]		чувственный - порочный	67
[+]	3	неэмоциональный – невинный	87	[+]	8	неэмоциональный – невинный	35
[-]		чувственный - порочный	6	[-]		чувственный - порочный	28
[+]	4	неэмоциональный – невинный	39	[+]	9	неэмоциональный – невинный	34
[-]		чувственный - порочный	43	[-]		чувственный - порочный	52
[+]	5	неэмоциональный – невинный	0	[+]	10	неэмоциональный – невинный	56
[-]		чувственный - порочный	91	[-]		чувственный - порочный	15

Таблица 9.

Влияние одежды на восприятие женского рекламного образа

№ изоб.	характер изображ ения	баллы		№ изоб.	характер изображ ения	баллы	
4	неэмоциональ ный - невинный	39		8	неэмоциональный - невинный	3 5	
4	чувственный - порочный	43		8	чувственный – порочный	2 8	
1 0	неэмоциональ ный - невинный	15		9	неэмоциональный - невинный	3 4	
1 0	чувственный - порочный	56		9	чувственный – порочный	5 2	
7	неэмоциональ ный - невинный	13		1	неэмоциональный - невинный	1 8	
7	чувственный - порочный	67		1	чувственный – порочный	5 9	
6	неэмоциональ ный - невинный	7		3	неэмоциональный - невинный	6	
6	чувственный - порочный	74		3	чувственный – порочный	8 7	
5	неэмоциональ ный - невинный	0		2	неэмоциональный - невинный	6	
5	чувственный - порочный	91		2	чувственный – порочный	1 1 4	

По результатам тестирования группы В можно говорить о том, что:

1) потенциальный потребитель эмоционально положительно откликается на изображение сексуального характера.

2) к образу женщины «вамп» или «стервы» отрицательно относятся не только женщины среднего возраста, как утверждают психологи, но как показывает данное исследование также и молодые девушки расценивают такие образы как опасные и искусственные. Характеристиками данных образов могут служить: сильно накрашенные глаза, напряженная поза и выражение лица, взгляд исподлобья.

3) в современном обществе ориентиром для подражания выступают сексуально раскрепощенные образы.

4) потенциальным потребителям по средствам рекламы на психологическом уровне внушается недовольство собой, рекламные образы в большей степени являются идеалами.

5) женский сексуальный образ в рекламе воспринимается потенциальной аудиторией как наиболее яркий индивидуальный, самодостаточный и жизнерадостный.

Что же касается оценки изображений с точки зрения сексуальности, то здесь можно сделать выводы о том, что неэмоциональность сродни невинности, но если к этой неэмоциональной невинности прилагается, хоть немного обнаженного тела, то показатели сразу приобретают отрицательные значения, образ становится чувственным и порочным.

Аналогичный опрос проводился и в группе С, но уже с изображениями завуалированной сексуальности.

Таблица 11.
Результаты тестирования изображений завуалированной сексуальности группы С

оценка	№ изоб.		отношение к образу		идентификация		настроение восприятия	
[+]	11	д/н	32	ид./п	54	я/ж	33	
[-]		о/и	32	нес./от.	24	неп./б	62	
[+]	12	д/н	28	ид./п	54	я/ж	68	
[-]		о/и	65	нес./от.	34	неп./б	15	
[+]	13	д/н	125	ид./п	79	я/ж	83	
[-]		о/и	9	нес./от.	9	неп./б	13	
[+]	14	д/н	38	ид./п	75	я/ж	61	

[-]		о/ и	46	нес./ от.	5	неп./б	27	
[+]	15	д/ н	80	ид./ п	16	я/ ж	42	
[-]		о/ и	16	нес./ от.	37	неп./б	42	
[+]	16	д/ н	46	ид./ п	95	я/ ж	57	
[-]		о/ и	51	нес./ от.	17	неп./б	18	
[+]	17	д/ н	87	ид./ п	38	я/ ж	32	
[-]		о/ и	21	нес./ от.	24	неп./б	44	
[+]	18	д/ н	100	ид./ п	64	я/ ж	62	
[-]		о/ и	13	нес./ от.	20	неп./б	22	
[+]	19	д/ н	14	ид./ п	50	я/ ж	48	
[-]		о/ и	92	нес./ от.	35	неп./б	35	
[+]	20	д/ н	94	ид./ п	98	я/ ж	117	
[-]		о/ и	16	нес./ от.	16	неп./б	6	

Данные в таблице представляют сумму баллов отрицательной или положительной оценки по каждому изображению. Сумма баллов бралась по модулю.

Основываясь на данных группы С, можно сделать вывод, что открыто сексуальный образ уступает образу с завуалированной сексуальностью. Респонденты группы С больше доверяют и испытывают симпатию к тем тестовым образам, которые

они могут ассоциировать с собой в наибольшей степени. Исходя из сравнительного анализа групп В и С, можно с уверенностью говорить о том, что использование образа с завуалированной сексуальностью в рекламе товаров, направленных на женскую аудиторию, является более выигрышным. Потенциальные покупатели будут сильнее идентифицировать себя с рекламным персонажем, испытывать доверие и симпатию, и, следовательно, транслировать данные эмоции и на сам рекламируемый товар.

По показателю идентификации положительные оценки также немного выше в группе С, но на изображения, содержащие элементы, ассоциируемые с сексуальными образами, у респондентов был отрицательный отклик. Для полного понимания как оценивают потенциальные потребители рекламу женской парфюмерии, проведем еще один сравнительный анализ полученных данных. Найдем общее среднее значение по группам.

Каждый ряд (линия диаграммы) является средним значением по ответам одного респондента (см. рис. 1). Всего же на диаграмме 22 ряда. Среднее значение по каждому респонденту в количестве 21 ряда и общее среднее значение ответов по экспериментальной группе. Анализ диаграммы по группе В показывает, что какой—либо простой закономерности в ответах не существует. Такое построение диаграммы может быть обусловлено неоднозначным восприятием сексуальной рекламы женской аудиторией. Психологи утверждают, что восприятие эротического образа не однозначно [1]. С уверенностью говорить о том, что сексуальная реклама будет иметь положительный отклик у потенциального потребителя, нельзя. Сексуальная реклама является «шоком». Реакцию на восприятие эротического образа потенциальными потребителями предугадать очень сложно; распространено мнение о том, что секс и эротика продает все, являющееся стереотипным.

Проанализируем результаты по группе С. По полученному изображению можно говорить о том, что восприятие изображений со скрытой сексуальностью оцениваются потенциальными потребителями более единообразно (Рис.2). Данные по каждому респонденту располагаются сравнительно плотно вокруг среднего значения по группе, повторяя контуры главного ряда. Отличительной особенностью данных группы С является наличие мнений, отличных от общей массы. Назовем данные ряды «антитолпа».




Рис. 1 — Результаты респондентов группы В

Оценки рекламных изображений данными респондентами кардинально различаются. Объяснить данный феномен простыми соображениями не представляется возможным. Полученные результаты требуют более внимательного и подробного изучения, с инструментарием, разработанным конкретно для изучения данного феномена. В настоящей работе целью изучения было воздействие эротики в рекламе женской парфюмерии на целевую аудиторию. Для объяснения данного результата можно высказать гипотезу, что это может быть вызвано тем, что современная молодежь воспитывается, в том числе и косвенно, более раскрепощенными сексуальными образами, транслируемыми СМИ, и для данных респондентов образ девушки приближенной к реальности не является уже столь привлекательным и идеальным.




Рис. 2 — Результаты респондентов группы С

Обсуждение и выводы

Проведённые исследования и вся совокупность полученных результатов показывает, что:

- I. К образу женщины «вамп» или «стервы» отрицательно относятся не только женщины среднего возраста, как утверждают психологи; молодые девушки также расценивают такие образы как опасные и искусственные;
- II. Потенциальным потребителям посредством рекламы часто внушается недовольство собой;
- III. Наиболее сексуальным потенциальный потребитель женской парфюмерии считает образ женщины не полностью обнаженной, а прикрытой одеждой, другими словами, реклама, которая, побуждает покупателя к размышлению, достигнет

наибольшего эффекта;

IV. Использование образа с завуалированной сексуальностью в рекламе товаров, направленных на женскую аудиторию, является более выигрышным. Потенциальные покупатели активнее идентифицируют себя с рекламным персонажем, испытывают доверие и симпатию, а, следовательно, транслируют данные эмоции и на сам рекламируемый товар;

V. Эмоционально яркие рекламные образы вызывают у потенциального потребителя высокий положительный отклик;

VI. Откровенно сексуальная реклама является психологическим «шоком» восприятие такой рекламы не контролируется. Реакцию на восприятие эротического образа потенциальными потребителями предугадать сложно, распространенное мнение, что секс и эротика продаёт всё, является скорее рекламным стереотипом.

Список литературы

1. Берн Ш. Гендерная психология. — СПб.: прайм—ЕВРОЗНАК, 2004.
2. Грошев И. В. Рекламные технологии гендера // Общественные науки и современность. 2000. № 4. С. 172-187.
3. Ульрих О. и Дениза Г. Различия в реакциях мужчин и женщин на изображения гендерных ролей в рекламе// Международный журнал исследований в маркетинге, том 21 (2004 г.), с. 77-88
4. Kilbourne, J. Beauty and the beast of advertising. // http://www.medialit.org/reading_room/article40.html.
5. <http://www.vedomosti.ru/newspaper/articles/2006/03/30/intim-ne-predlagat>
6. Шугерман Джозеф Искусство создания рекламных посланий. Справочник выдающегося американского копирайтера. М. Издательство: Эксмо. Серия: Академия рекламы. 2010 г.
7. Шиманов, Д. Потребительское поведение «М» и «Ж». Маркетинг pro №9. 2007.
8. Ковриженко, М.К., «Эротические образы современной рекламы»// Ломоносовские чтения, том 2, 2002.
9. Грошев И. В. Образ женщины в рекламе. — Женщина.Гендер, Культура. М., 1999. С.2—3.
10. Вильямсон Ю. Создание гендера//Труды СПбФ ИСПАН. СПб., 1997.

SMART-ТЕХНОЛОГИЯ ДИСТАНЦИОННОГО ОБУЧЕНИЯ ДЛЯ ЛЮДЕЙ С ОГРАНИЧЕННЫМИ ВОЗМОЖНОСТЯМИ ЗРЕНИЯ НА ОСНОВЕ ПОДХОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Г. А. Самигулина¹, А.С. Шаяхметова²

¹Институт информационных и вычислительных технологий КН МОН РК

galinasamigulina@mail.ru

²Казахский Национальный технический университет им. К.И. Сатпаева

asemshayakhmetova@mail.ru

Отличительной чертой современного мира стало глобальное развитие информационных технологий. Особенно эффективно их применение в образовании. На сегодняшний день дистанционное обучение (ДО) является одним из наиболее активно развивающихся направлений в мировой образовательной среде. Появилось понятие Smart education. Это новый подход в образовании, обеспечивающий высокий уровень развития, соответствующий задачам и возможностям современного мира. Он определяет взаимосвязь между знаниями, используемыми технологиями и методами преподавания. Переход на Smart - education дает возможность широкого использования инновационных технологий. Система ключевых особенностей Smart - образования предлагается в статье [1]. В исследовании [2] рассматривается технология системы Smart – education, которая подключается онлайн к виртуальному университету и базируется на веб-технологиях. Интеллектуальная обучающая система определяет слабые и сильные стороны обучающихся в режиме реального времени. Выбирается возможный уровень обучения и алгоритм безопасности. В статье [3] разработана модель Smart – education, которая строится на основе результатов проведенного опроса. Предложенная модель состоит из взаимосвязанных между собой курсов, методов и оценок обучения. С появлением Smart – education, возникли такие термины как: Smart технология, Smart – learning, Smart – кафедра, Smart – класс, Smart – книга. Появился Smart – университет, который осуществляет свою деятельность в соответствии с нормативными актами, а также помогает взаимодействовать похожим кафедрам и организациям путем создания и использования общего контента.

В статье [4] разработана онтологическая система Smart - класса. Система помогает понять взаимосвязи и анализировать имеющееся «умное оборудование» в классе, определяет их функции, программное обеспечение, подходы преподавания и обучения. Понятия Smart - learning [5] включает в себя гибкое обучение, состоящее из большого количества источников, максимального разнообразия мультимедиа (аудио, видео, графика), способности быстро и просто настраиваться под уровень и потребность обучающегося с помощью мобильных устройств. Цель Smart обучения – передать часть интеллекта, опыта преподавателя в среду e - learning. В работе [6] проводится сравнительное исследование Smart-обучения от традиционного обучения. По результатам опросов обучающиеся предпочитают учебные материалы Smart-образования, которые отличаются мобильностью, целостностью и оказывают огромное влияние на эффективное и качественное обучение.

Все эти проблемы актуальны для людей с ограниченными возможностями, особенно для организации ДО обучения людей с ограниченными возможностями зрения (ЛОВЗ).

Постановка задачи формулируется следующим образом: необходимо разработать Smart - технологию и информационную систему дистанционного обучения для людей с ограниченными возможностями зрения на основе современных методов

искусственного интеллекта с целью изучения новейших технологий на дорогостоящем оборудовании в лабораториях коллективного пользования (ЛКП).

Решение данной задачи позволит создать ЛОВЗ благоприятные условия, которые помогают социальной адаптации в обществе и обеспечивают конкурентоспособность в образовании. Предложенная информационная система реализуется с использованием Национальной научной лаборатории коллективного пользования информационных и космических технологий при КазНТУ имени К.И. Сатпаева и может быть использована в качестве компоненты MOODLE (Modular Object-Oriented Dynamic Learning Environment).

Для многих незрячих людей компьютерная техника стала необходимым и единственным средством для работы и общения. При создании Smart- технологии дистанционного обучения ЛОВЗ необходимо учитывать возможность обеспечения для них полноценной работы на персональных компьютерах. Для этого существуют специальные программы экранного доступа. В программе экранного доступа Cobra (<http://speech-soft.ru/prog-for-blind>) информация представляется пользователю не только посредством речевого вывода, но и через интерфейс. Программа речевого доступа к экрану NVDA (<http://ru.nvda-community.org/>) выполняет стандартные задачи под Windows. Программное обеспечение для слабовидящих и незрячих Virgo (http://www.tibsev.org/help/Virgo4_2010.pdf) позволяет пользователю выбирать, какую информацию показывать на брайлевском дисплее, а какую произносить голосом. Предлагает выбор двух режимов доступа: режим фокуса и режим проводника. Режим фокуса активизируется в Windows или одной из его программ с помощью клавиатуры или мыши. Программа следует за фокусом и передает всю важную информацию с экрана через брайль и речевой вывод. В программе экранного доступа Window-Eyes (<http://www.windoweyesforoffice.com/>) информация конвертируется в звуковой формат через панель Settings. Экранный диктор Narrator (<http://windows.microsoft.com>) способен читать вслух информацию, которая появляется на экране компьютера. Используется технология распознавания текста и озвучивания с помощью голосового синтезатора, который выбирается из списка заранее заданных голосов. В данной работе используется программа экранного доступа JAWS [7]. Программа разработана группой слепых и слабовидящих людей из Freedom Scientific штат Флорида, США. Она даёт возможность получить доступ ЛОВЗ к свободному использованию персонального компьютера с операционной системой Microsoft Windows. С помощью синтезатора речи, через аудио-карту компьютера, информация с экрана озвучивается голосом вслух, обеспечивая возможность речевого доступа к разнообразным программам, приложениям и позволяет без ограничений пользоваться клавиатурой Брайля.

Для повышения эффективности функционирования систем ДО в последнее время активно используются подходы искусственного интеллекта (ИИ). Благодаря своим способностям к самоорганизации и обучению, эти подходы рассматриваются как перспективные средства при создании новейших технологий ДО. Особенностью данных систем является необходимость обработки огромного потока многомерных данных в реальном масштабе времени. В развитии интеллектуальных систем ДО хорошего результата можно достичь путем комбинации различных методов ИИ: нейронных сетей, генетических алгоритмов, искусственных иммунных систем, нейро-нечеткой логики, теории нечетких множеств. Нейро-нечеткая логика лежит в основе методов работы с неточностью, гранулированием информации, приближенными рассуждениями и вычислениями со словами. Нейровычисления отражают способность к обучению, адаптации и идентификации. Генетические алгоритмы позволяют систематизировать случайный поиск и достигать оптимального значения характеристик. Искусственные иммунные системы прогнозируют [8, 9] результаты

обучения ЛОВЗ. Вероятностные вычисления обеспечивают базу для управления неопределенностью.

Разработаны онтологические модели (ОМ), которые определяют отношения между объектами в разрабатываемой системе ДО. Построена комбинированная онтологическая модель ДО для ЛОВЗ, которая состоит из ОМ обучающегося, ОМ обучения и ОМ лаборатории коллективного пользования.

При построении ОМ обучающегося, учитываются признаки ЛОВЗ по следующим составляющим: текущее состояние здоровья по зрению, интеллектуальный, мотивационный, психологический, физиологический и волевой потенциал личности.

При разработке ОМ обучения создается унифицированная структура учебной дисциплины, что позволяет более эффективно осуществлять интеграцию учебных курсов.

Онтологическая модель лаборатории коллективного пользования описывает доступ ЛОВЗ к суперкомпьютеру для проведения лабораторных, практических работ и обработке больших объемов данных на вычислительных кластерах. Вычислительный кластер состоит из сервера, системы хранения данных, коммутаторов и источника бесперебойного питания. Все перечисленные устройства взаимосвязаны между собой. Универсальный сервер используется для работы разных приложений в рамках информационных центров, управляет задачами и занимается распределением их между вычислительными узлами кластера. На сервере ЛКП создается виртуальная машина, предоставляется удаленный доступ и необходимое программное обеспечение для каждого ЛОВЗ.

Интеллектуальная информационная система дистанционного обучения (ИИСДО) на основе подходов ИИ имеет модульный характер [10]. Основными модулями ИИСДО являются:

1. Информационный блок, который содержит методы и средства хранения информации, включает в себя разработку баз данных, баз знаний, электронные учебники, электронные библиотеки, каталоги, справочную систему в виде поисковой системы и учебных консультаций (чат, форум).

2. Интеллектуальный блок, осуществляющий обработку многомерных данных в режиме реального времени на основе подходов ИИ и прогнозирование результатов обучения.

3. Обучающий блок, с помощью которого реализуются методы, средства и формы передачи обучающей информации, направленные на конкретного обучающегося с учетом его индивидуальных характеристик. Особенностью данного блока является организация выполнения лабораторных и практических работ в on-line режиме. Организация доступа к ЛКП является одной из наиболее сложных задач для практической реализации.

4. Контролирующий блок предназначен для оценки знаний обучающихся, отслеживания процесса обучения и успеваемости.

Таким образом, данная Smart - технология решает задачу эффективного дистанционного обучения ЛОВЗ работе на высокопроизводительных вычислительных кластерах в Национальной научной лаборатории коллективного пользования информационных и космических технологий (г. Алматы, Казахстан).

Разработанная технология имеет ряд достоинств [11] :

- удобный интерфейс для ЛОВЗ с использованием звукового сопровождения, который позволяет эффективно работать с ИИСДО;

- учитываются индивидуальные характеристики и особенности восприятия учебного материала ЛОВЗ, предусмотрена возможность адаптировать учебный процесс, с учетом индивидуальных характеристик;

- осуществляется эффективная обработка многомерных данных на основе подходов ИИ и прогнозирование результатов обучения;
- создается оптимальная модель обучения, которая адаптируется к модели обучающегося;
- возможность выполнения лабораторных и практических работ ЛОВЗ в реальном масштабе времени на вычислительных кластерах в ЛКП;
- возможность расширения системы за счет модульной структуры ИИСДО;
- распределенные вычисления для обработки многомерных данных на основе подходов ИИ;
- позволяет эффективно осваивать новейшие информационные технологии людьми с нарушением зрения на дорогостоящем оборудовании и обеспечивает оперативное управление процессом обучения.

Список литературы

- 1 Tikhomirov V. The world on a way to smart education: new opportunities // Open education. – 2011. - № 3. – P. 22-28.
- 2 Sik Hong You. Smart Education System // The Journal of The Institute of Internet, Broadcasting and Communication. – 2013. – Vol. 13. – P. 255-260.
- 3 Bae Youngkwon. Development of a Smart Education Model for Field Application of Smart Education // Journal of Korean Society for Internet Information. – 2012. - Vol.13. – P. 77-92.
- 4 Uskov V.L. Bakken J.P. and Pandey A. The ontology of next generation smart classrooms // Smart Education and Smart e-Learning. Springer International Publishing Switzerland, 2015. – Volume 41. – P. 3 -15.
- 5 Burdescu D.D. Tesys – An e-learning system // Proceedings of the IX International Scientific conference «Quality and Efficiency in e-Learning». – 2013. – Vol. 3. – P. 633-640.
- [6] Tikhomirov V. The world on a way to smart education: new opportunities // Open education. – 2011. - № 3. – P. 22-28.
- 6 Klimova B., Simonova I. Study Materials in Smart Learning Environment – A Comparative Study // Smart Education and Smart e-Learning Smart Innovation, Systems and Technologies. – 2015. – Vol. 41. – P. 81-90.
- 7 The World's Most Popular Windows Screen Reader. - 2014. [the electronic resource]: <http://www.freedomscientific.com/>.
- 8 Samigulina G. Development of the decision support systems on the basis of the intellectual technology of the artificial immune systems // Automatic and remote control. Springer. - 2012. - Vol. 74. - №2. - C. 397 - 403.
- 9 Galina A. Samigulina, Zarina I. Samigulina. Intellectual systems of forecasting and control of complex objects based on artificial immune systems. Monograph. –Yelm, WA.: Science Book Publishing House, USA, 2014, - 172 p.
- 10 Samigulina Galina, Shayakhmetova Assem. The information system of distance learning for people with impaired vision on the basis of artificial intelligence approaches // Proceeding of the II International conference on Smart Education and E-learning. – Italy, Sorrento: Springer. - 2015.– P. 255-263.
- 11 Самигулина Г.А., Шаяхметова А.С. Построение интеллектуальной системы дистанционного обучения для людей с ограниченными возможностями зрения // Труды IV Междунар. научного конгресса «Наука и образование в современном мире». – Новая Зеландия, Окленд: Elsevier. – 2015. – С.848-851.

ОБЩЕСТВО В РАКУРСЕ ТУРБУЛЕНТНОСТИ

В.П.Сизиков¹, В.И. Разумов²

¹Омский государственный университет путей сообщения, v_p_sizikov@mail.ru

²Омский государственный университет им. Ф.М. Достоевского, razumovvi@omsu.ru

1. Введение. Приведён пример применения ДИС-технологии, которой присущи одновременно качества системной методологии, языка программирования на уровне оболочки экспертных систем и аппарата имитационного моделирования. ДИС-технология позволяет быстро получать на качественном уровне то, что обычно требует долгих исследований, проведения затратных и экологически вредных экспериментов. В работе [1] был установлен системный статус феномена турбулентности. Теперь проследим, как этот феномен проявляется в обществе.

При моделировании процессов в обществе их тонкая и богатая природа не дополняется выявлением оснований методов моделирования. Есть ряд удачных объектов, положенных в основу для разработок классов соответствующих моделей, среди них: маятники, струны, осцилляторы; особое место занимают нейроны и нейросети, относительно которых образованы модели формальных нейронов и нейросетей; динамические информационные системы (ДИС) как базовые объекты ДИС-технологии, образованные как онтологически-осмысленные конструкции в ранге моделей объектов произвольного типа [2–5]. При обращении к обществу оказывается, что на настоящее время отсутствуют даже основания к построению социальной теории и теории общества. Существующие модели не позволяют давать надёжные прогнозы для процессов в обществе. В интересах продемонстрировать потенциал ДИС-технологии в изучении общества, в частности, использовать полученные результаты по изучению феноменов турбулентности, обратимся к анализу взаимодействия выделенных Р. Коллинзом процессов модернизации: бюрократизация, демократизация, индустриализация, секуляризация [6, С. 264–293], которые будут представлены в виде когнитивной ячейки [1–5].

2. Сущность и модель турбулентности. Напомним, что ДИС-технология есть сформированный на базе теории ДИС [2–5] аппарат математического моделирования, которому присущи качества языка программирования по организации и осуществлению имитаций. А рабочий объект ДИС-технологии есть ДИС как оргграф с двумя типами рёбер (ведущими, контролирующими) и процессом информационного функционирования (ПИФ) на нём как процессом перераспределения между его вершинами двух типов ресурса (актива, пассива) в последовательности из актов трёх типов: A_c – акт сбора актива в пассив по контролирующим рёбрам; A_t – акт трансформации пассива в актив в некоторых вершинах; A_d – акт перераспределения актива по ведущим рёбрам.

При взгляде извне поведение турбулентного характера представляется хаосом из вихрей, несовместимых с законами сохранения энергии без привлечения гипотез о дополнительных внутренних силах или вмешательствах извне. Этих проблем не будет,

если исходить из внутренних атрибутов системы, и тогда турбулентность является просто отражением поведения одной системы в рамках другой, более широкой системы. Почти всё и всегда при наблюдении извне выдаёт себя в той или иной мере как турбулентность. Наблюдатель может по-разному воспринимать и регулировать режим турбулентности, но сам по себе факт наличия турбулентности от него не зависит.

Пусть три вершины v_0, v_1, v_2 представляют модель исходной системы G в ранге триады с кругооборотом в ней ресурса по циклу $v_0 \rightarrow v_1 \rightarrow v_2 \rightarrow v_0$. Добавление вершины v_3 с дополнительно возможным кругооборотом ресурса по циклу $v_0 \rightarrow v_3 \rightarrow v_2 \rightarrow v_0$ в триаде U даёт в целом модель более широкой системы H в ранге когнитивной ячейки. При этом подсистема U организует управление турбулентной подсистемой G в H .

Для запуска ПИФ у ячейки H надо задать распределение активов r_i и пассивов q_i по вершинам v_i и определить, как меняются от компонента к компоненту ПИФ уровень трансформации λ_i пассива в актив в v_i и относительные проводимости $f_c(v_j, v_i)$, $f_d(v_i, v_j)$ контролирующего и ведущего ребра, проводящих ресурс от v_i к v_j ($i, j=0, 1, 2, 3$). Из простоты считаем, что общий объём ресурса в ячейке равен 1 – условной единице. А при взаимодействии проводимости рёбер определяются текущим образом формулами: $f_d(v_i, v_j) = a_{ij}(r_j + q_j)$, $f_c(v_j, v_i) = b_{ij}(r_j + q_j)$, где $0 \leq a_{ij} = (a_i a_j)^{0.5} \leq 1$, $0 \leq b_{ij} = (b_i b_j)^{0.5} \leq 1$ – постоянные взаимодействия, а $0 \leq a_i \leq 1$, $0 \leq b_i \leq 1$ – постоянные мотиваций взаимодействия, свои в каждой вершине v_i ($i, j=0, 1, 2$). Для выявления автономных качеств системы все a_i , b_i и $0 \leq \lambda_i \leq 1$ считаются неизменными в конкретном ПИФ. Кроме того, режим, на который выходит ПИФ ячейки, лишь в исключительных случаях зависит от начального распределения активов r_i и пассивов q_i , т.е. их можно задать практически любыми, дающими в общей сумме 1.

Каждому набору из 12 значений λ_i, a_i, b_i ($i=0, 1, 2, 3$) отвечает ПИФ ячейки, поведение графика которого выступает как режим в определённой классификации. Каждой вершине ячейки отвечают два графика изменения в ней актива и пассива. Важно отслеживать, когда и какой складывается режим ПИФ ячейки H и каковы его особенности на триаде G . Особенности ПИФ на G в H и раскрывают суть турбулентности.

3. Общий мониторинг турбулентности. Ограничимся вариантами, когда среда подобна однородному по природе материалу, для чего считаем одинаковыми все a_i , обозначая их через a , и все b_i , обозначая их через b ($i=0, 1, 2$). Так что окажется $a_{ij}=a$ и $b_{ij}=b$ ($i, j=0, 1, 2, 3$). Беря это на учёт, определимся с минимальной серией экспериментов. Так, во избежание помех со стороны сумму $\lambda_0 + \lambda_1 + \lambda_2 + \lambda_3$ берём близкой к 1. А для выявления тонкостей турбулентности важно, чтобы за рамками части G почти не было ресурса в системе H , поэтому выбираем λ_3 малым. Пусть также для начала будет $\lambda_0 = \lambda_1 = \lambda_2$. От a и b , в главном, зависит мощность взаимодействия, из удобств полноты отражения результатов эксперимента начнём с $a=b=0,5$. Итак, для начала возьмём $\lambda_0 = \lambda_1 = \lambda_2 = 0,3$, $\lambda_3 = 0,06$, $a=b=0,5$. Расчёт ПИФ у ячейки при таких данных даёт графики изменения величин актива (ряд 1) и пассива (ряд 2) в четвёрке вершин (рис. 1 слева). Для сравнения приведено поведение ПИФ отдельно взятой триады G при $\lambda_0 = \lambda_1 = \lambda_2 = 0,3$ (рис. 1 справа).




Рис. 1. Базовые режимы турбулентности (слева) и свободного функционирования (справа) подсистемы G .

Чтобы проследить, как зависит турбулентность от воздействий U на G , приведены случаи, когда $a=b=0,5$, но $\lambda_0=\lambda_1=\lambda_2=\lambda_3=0,23$ (рис. 2 слева) и $\lambda_0=\lambda_1=\lambda_2=0,04$, $\lambda_3=0,8$ (рис. 2 справа). Эти варианты берём и при факте властной неоднородности G . Сначала при избытке тормозов в вершине v_1 , не входящей в U : $\lambda_0=0,1$, $\lambda_1=0,6$, $\lambda_2=0,2$, $\lambda_3=0,06$ (рис. 3 слева) и $\lambda_0=0,02$, $\lambda_1=0,3$, $\lambda_2=0,04$, $\lambda_3=0,6$ (рис. 3 справа). При избытке тормозов в общей для G и U вершине различим случаи, когда такой вершиной выступает v_2 или v_0 : $\lambda_0=0,2$, $\lambda_1=0,1$, $\lambda_2=0,6$, $\lambda_3=0,06$ (рис. 4 слева), $\lambda_0=0,04$, $\lambda_1=0,02$, $\lambda_2=0,3$, $\lambda_3=0,6$ (рис. 4 справа), $\lambda_0=0,6$, $\lambda_1=0,1$, $\lambda_2=0,2$, $\lambda_3=0,06$ (рис. 5 слева), $\lambda_0=0,3$, $\lambda_1=0,02$, $\lambda_2=0,04$, $\lambda_3=0,6$ (рис. 5 справа). А для учёта влияния постоянных взаимодействия a и b приведены случаи, где $\lambda_0=\lambda_1=\lambda_2=0,3$, $\lambda_3=0,06$, но $a=0,5$, $b=0,05$ (рис. 6 слева) и $a=0,05$, $b=0,5$ (рис. 6 справа).




Рис. 2. Случаи умеренного (слева) и мощного (справа) управления.




Рис. 3. Случаи избытка тормозов в недоступном прямому управлению (слабому – слева и сильному – справа) элементе в G .




Рис. 4. Случаи избытка тормозов в доступном прямому управлению (слабому – слева и сильному – справа) элементе в G .




Рис. 5. Случаи избытка тормозов в доступном наблюдению при управлении (слабом – слева и сильном – справа) элементе в G .




Рис. 6. Случаи ослабленной (слева) и усиленной (справа) работы пассива в системе.

В приведённых вариантах подсистема U управляет подсистемой G через изменение величины λ_3 . При этом наблюдаются вершины триады U , но никак не v_1 . Можно через v_3 управлять и изменением объёма ресурса в системе, т.е. условной единицы, но это не приносит новых качеств к избранным вариантам.

Явно видно, что на правом рисунке 1 ПИФ почти периодичен, причём имеет место качество строгой посменности пиков ресурса в вершинах триады в циклическом порядке $v_0 \rightarrow v_1 \rightarrow v_2 \rightarrow v_0$. По-другому говоря, здесь мы имеем режим гравитации с преобладанием проявлений актива над пассивом. Присоединение вершины v_3 оставляет локальное поведение ПИФ прежним, т.е. в режиме гравитации. Однако при этом увеличивается характерный размер периода в v_1 . На каких-то этапах строгая посменность прослеживается, но через некоторое время порядок пиков меняется. Эта перемена порядка и есть проявление турбулентности у G в H .

Заметим, что поведение ПИФ в v_3 почти не согласуется с остальным, т.е. поведение ПИФ в G более стройное, чем в U . И это продиктовано, в основном, малостью значения λ_3 . Так, на рисунках 2 представлены варианты с достаточно большим значением λ_3 . На левом из них все вершины системы равноправны: $\lambda_0=\lambda_1=\lambda_2=\lambda_3=0,23$. Так, по-прежнему имеем режим гравитации, причём поведение ПИФ в v_3 на качественном уровне повторяет его поведение в v_1 . Но характерный размер периода у ПИФ в v_1 , v_3 примерно вдвое больше такового в v_0 , v_2 , и строгой посменности не выявляется даже на локальных этапах. Здесь можно говорить о проявлении турбулентности на уровне хаоса, несмотря на то, что на деле порядка в поведении ПИФ весьма предостаточно.

Дальнейшее увеличение λ_3 должно сопровождаться уменьшением λ_0 , λ_1 , λ_2 . При этом всё больше будет нарушаться стройная картина с пиками, характерная для режима гравитации, и всё чётче будет проявляться режим электромагнетизма с преобладанием проявлений пассива над активом, характерный пример которого и даёт правый рисунок 2. На этом рисунке v_3 выступает в роли положительного полюса электрического диполя, v_0 – отрицательного, а v_2 оказывается в роли магнитной среды как проводника электрического взаимодействия. Теперь наряду с тем, что G проявляет турбулентность, в U могут регулярно поступать молнии из v_0 в v_3 . Обратим внимание, что молний нет в G , видимо, этому мешает её однородность.

На рисунках 3–5 представлены варианты, когда в G есть неоднородности. На рисунках 3 нарушителем однородности G является вершина v_1 , не входящая в U . Здесь, как и в предыдущем случае, при увеличении λ_1 всё больше будет нарушаться режим гравитации, и проявляться режим электромагнетизма. Но теперь это будет происходить в G , где v_1 явится в роли положительного полюса электрического диполя, v_0 – отрицательного, а v_2 – в роли магнитной среды. На левом рисунке 3 управление слабо. При этом v_3 не будет полюсом диполя, тем не менее, поведение ПИФ в ней будет аналогично его поведению в v_0 , что позволит надёжно наблюдать за молниями, происходящими в G . На правом рисунке 3 управление велико. Здесь электромагнетизм присущ и U , в ней v_3 оказывается в роли положительного полюса электрического диполя при тех же магнитной среде v_2 и отрицательном полюсе v_0 как источнике молний.

На рисунках 4 нарушает однородность G вершина v_2 , в которую U напрямую подаёт управляющие воздействия. На левом рисунке 4 управление слабо. Здесь тоже имеем сразу два электрических диполя, у них v_2 явится в роли общего положительного полюса, v_1 , v_3 – отрицательных полюсов, а v_0 – в роли магнитной среды. Теперь молнии будут поступать регулярно в v_2 из, соответственно, v_1 в G и v_3 в U , и управляющие воздействия могут представлять как удары молний. А на правом рисунке 4 управление велико, так электромагнетизм проявится лишь в U , в ней v_3 выступит в роли положительного полюса электрического диполя, v_0 – отрицательного, а v_2 – в роли магнитной среды, и некоторые наблюдения в v_3 будут сопровождаться ударами молний.

На рисунках 5 нарушает однородность G вершина v_0 , из которой U напрямую берёт наблюдения. На левом рисунке 5 управление слабо. Здесь имеем сдвоенный электрический диполь, у которого v_0 выступает в роли положительного полюса, v_2 – отрицательного, а v_1, v_3 – в роли магнитной среды, причём графики ПИФ в v_1, v_3 идентичны один другому. Это, по сути, самый надёжный и безопасный вариант управления турбулентностью. А на правом рисунке 5 управление велико, и имеем двухуровневый электромагнетизм с общей магнитной средой v_2 . И в U проявляется электрический диполь с положительным полюсом v_3 и отрицательным v_0 . И в G проявляется электрический диполь с положительным полюсом v_0 и отрицательным v_1 . Так что v_0 оказывается в роли одновременно и положительного, и отрицательного полюса. Возможно, это пример двухзвенной линейной молнии из v_1 в v_3 .

Для качественных перемен режима ПИФ решающее значение имеет лишь отношение a/b . И на рисунке 6 представлены два случая: с $a/b > 1$ и с $a/b < 1$. Так, рост отношения a/b приводит сначала к хаосу амплитуд и периодов, а затем и вовсе к режиму сотрясения (левый рисунок 6) с испусканием затухающих волн при каждой трансформации пассива в актив, причём затухание длится тем больше, чем больше a/b . Но это при слабом управлении. При сильном управлении аналогичное будет в русле электромагнетизма, доходя до испускания электромагнитных волн. А с уменьшением a/b поведение актива в каждой вершине всё больше обретает тенденцию постоянно убывать, пока не настанет момент трансформации в ней пассива в актив, как оно представлено на правом рисунке 6. При этом характер поведения режима ПИФ остаётся, в главном, таким же, как и при $a/b = 1$. В частности, при сильном управлении будет проявляться электромагнетизм, и тоже с тенденцией на постоянное убывание величины актива.

Итак, приступим к анализу и интерпретациям результатов. Осуществим это для случая, когда ячейка H отражает модернизации в обществе.

4. Основные выводы по обществу. Теперь ячейка H отражает модернизации в обществе. При этом вершины v_0, v_1, v_2, v_3 представят, соответственно, демократизацию, секуляризацию, индустриализацию и бюрократизацию [6]. Первые три задают основу G социального развития, а последняя контролирует и регулирует этот факт. Так, имеем ряд выводов.

1. Даже малое влияние бюрократизации приводит к хаосу в социальном развитии, к эффектам турбулентности.

2. При мощном влиянии бюрократизации, при котором объём ресурса в контуре социального развития может меняться в разы, проявляется эффект поддержания индустриализации, но за счёт подавления демократизации и секуляризации.

3. При достаточно серьёзной неоднородности блока социального развития в нём, как правило, неизбежно проявление контрмер. Возможны следующие варианты.

- 3.1. Если центром неоднородности выступает секуляризация, то при слабом влиянии бюрократизации вероятны контрмеры в адрес секуляризации со стороны демократизации, а при мощном влиянии бюрократизации контрмеры достаются и ей.

3.2. Если центром неоднородности выступает индустриализация, то непосредственное умеренное воздействие на неё бюрократизации может, однако, предстать в ранге контрмер, а при мощном влиянии бюрократизации она получает контрмеры со стороны демократизации.

3.3. Если центром неоднородности выступает демократизация, то при слабом влиянии бюрократизации демократизация испытывает контрмеры со стороны индустриализации, а при мощном влиянии бюрократизации вероятно двухступенчатая контрмера: от индустриализации к демократизации и далее к бюрократизации.

4. При преобладании потребностей над производством в системе ($a/b > 1$) её функционирование сопровождается фрустрациями с достаточно быстрым их нивелированием, а при преобладании производства над потребностями ($a/b < 1$) функционирование становится сбалансированным.

5. Заключение. Итак, для четырёх процессов, составляющих систему модернизации в обществе, с применением ДИС-технологии установлены их корреляции с разработанными режимами ПИФ ДИС. В серии имитационных экспериментов удалось установить функциональные зависимости компонентов системы модернизации: бюрократизация, демократизация, индустриализация, секуляризация. Выводы по проведенному исследованию позволяют находить объяснения для широкого спектра процессов в обществе, а также представленные в работе модели позволяют прогнозировать динамику развития обществ, в том числе, с учётом развёртывания разнообразных проектов.

Есть основания утверждать перспективность идей о формировании онтологически осмысленных теорий и моделей с их апробациями на объектах разнообразной природы, где важное место должны занимать социальные системы и общество.

Список литературы

1. Сизиков В.П. Турбулентность: системный статус и управление / В.П. Сизиков // Теоретические и прикладные аспекты современной науки: Сб. науч. тр. по матер. IX Междун. науч.-практ. конф. в 6 ч. – Белгород : ИП Петрова М.Г., 2015. – Ч. II.; То же [Электронный ресурс]. Режим доступа: <http://www.issledo.ru>.
2. Разумов В.И. Основы теории динамических информационных систем / В.И. Разумов, В.П. Сизиков. – Омск: ОмГУ, 2005. – 212 с.; То же [Электронный ресурс]. Режим доступа: <http://www.omsu.ru/file.php?id=4264>.
3. Разумов В.И. Информационные основы синтеза систем. В 3 ч. Ч. I. Информационные основы системы знаний / В.И. Разумов, В.П. Сизиков. – Омск: ОмГУ, 2007. – 266 с.; То же [Электронный ресурс]. Режим доступа: <http://www.omsu.ru/file.php?id=2594>.
4. Разумов В.И. Информационные основы синтеза систем. В 3 ч. Ч. II. Информационные основы синтеза / В.И. Разумов, В.П. Сизиков. – Омск: ОмГУ, 2008. – 340 с.; То же [Электронный ресурс]. Режим доступа: <http://www.omsu.ru/file.php?id=4265>.
5. Разумов В.И. Информационные основы синтеза систем. В 3 ч. Ч. III. Информационные основы имитации / В.И. Разумов, В.П. Сизиков. – Омск: ОмГУ, 2010. – 640 с.; То же [Электронный ресурс]. Режим доступа: <http://www.omsu.ru/file.php?id=6759> (part1); <http://www.omsu.ru/file.php?id=6760> (part2).
6. Коллинз Р. Макроистория: Очерки социологии большой длительности / Р. Коллинз. – Пер. с англ. Послесл. Н.С. Розова. – М.: УРСС: ЛЕНАНД, 2015.

НЕЙРОСЕТЕВЫЕ КОМПЬЮТЕРНЫЕ ТЕХНОЛОГИИ В ДИАГНОСТИКЕ И ПРОГНОЗИРОВАНИИ ОСЛОЖНЕНИЙ В ГНОЙНОЙ ТОРАКАЛЬНОЙ ХИРУРГИИ

А.А. Соломаха, В.И. Горбаченко

Пензенский государственный университет, anatoly.solomakha@yandex.ru

Летальность у больных гнойно-деструктивными заболеваниями легких, при наличии осложнений, достигает 80-90%. Разработаны нейросетевые и нейронечеткие информационные системы диагностики и прогнозирования гнойно-воспалительных осложнений в хирургии гнойно-деструктивных заболеваний легких, синдрома эндогенной интоксикации с почечной дисфункцией, печеночной недостаточности, риска развития кровотечений. Разработана методика балльной оценки степени тяжести состояния больных гнойно-деструктивными заболеваниями легких на догоспитальном и стационарном этапах. Это позволило улучшить диагностику и прогнозирование осложнений у данных больных.

Ранняя диагностика, лечение, профилактика и прогнозирование риска возникновения осложнений у больных гнойно-деструктивными заболеваниями лёгких являются актуальной и нерешённой до настоящего времени медицинской проблемой в нашей стране и за рубежом. Нередко молниеносно развивающийся распад лёгочной ткани, приводит к развитию тяжёлой эндогенной интоксикации, печёночной и почечной недостаточности. Летальность при данных осложнениях достигает 80 – 90 %. Поэтому известно, что дополнительные ежегодные финансовые ассигнования, которые направляет российское правительство на борьбу с последствиями гнойной хирургической инфекции составляет от 5 до 15 миллиардов рублей [1, 3].

Таким образом, для реализации государственной задачи улучшения диагностики и прогнозирования осложнений у больных гнойно-деструктивными заболеваниями лёгких нами была разработана и внедрена в клиническую практику балльная шкала оценки тяжести состояния больных гнойно-деструктивными заболеваниями лёгких, на её основе разработаны нейросетевые и нейро-нечёткие информационные системы диагностики гнойно-воспалительных осложнений в хирургии гнойно-деструктивных заболеваний лёгких, синдрома эндогенной интоксикации, синдрома эндогенной интоксикации с почечной дисфункцией, печёночной недостаточности, риска развития кровотечений.

Наше исследование началось с изучения отечественной и зарубежной литературы, клинико-лабораторных параметров 557 больных гнойно-деструктивными заболеваниями лёгких. Установили, что наиболее частыми причинами неблагоприятных исходов у данных больных являлись трудности выбора критериев для объективизации оценки степени тяжести состояния больных. Это и приводит к их поздней госпитализации.

Поэтому нами была разработана методика балльной оценки степени тяжести состояния больных гнойно-деструктивными заболеваниями лёгких на догоспитальном и стационарных этапах. При первичном осмотре больного были предложены три группы факторов: пол, возраст и анамнестические данные; жалобы больного, данные обследования. Каждый признак оценивался в баллах. Всего необходимо изучить двадцать шесть признаков. В том случае, если общая сумма баллов была менее двадцати, появлялась необходимость в осуществлении дифференциальной диагностики и дообследовании больного. Когда сумма баллов находилась в пределах от 20 до 40 баллов, состояние больного расценивалось среднетяжёлым. Это мотивировало торакальных хирургов к организации специализированной подготовки больного в условиях палаты интенсивной терапии хирургического отделения. Если баллы распределялись в пределах 40 и более, состояние уже такого больного было оценено тяжёлым. Поэтому коррекция жизненно – важных функций организма пациента проводилась врачом-реаниматологом в условиях реанимационного отделения [2].

Клиническая апробация балльной шкалы оценки степени тяжести состояния больных гнойно-деструктивными заболеваниями лёгких осуществлена на выборке, состоящей из информации о 235 пациентах. Нами было установлено, что дополнительное обследование для верификации диагноза потребовалось 31 (13,2 %) больному. Подготовка в условиях палаты интенсивной терапии хирургического отделения явилась целесообразной для 208 (86,8 %) больных. Однако при изучении торакальных карт у 12 (5,1 %) больных с количеством баллов в пределах 30 – 35, было установлено, что данных конкретных пациентов было бы рациональнее лечить в реанимационных условиях.

Нами была предложена балльная шкала для оценки степени риска развития осложнений в плевральной полости на основе рентгенологических, сцинтиграфических, спирографических, бронхоскопических и торакоскопических данных, которые широко применяются в клинической практике [2]. Однако, несмотря на, имеющиеся возможности прогнозирования низкого, среднего или высокого риска развития осложнений в плевральной полости, до сих пор клиницисты не используют перечисленный полный перечень факторов. По отдельным параметрам возможна лишь верификация диагноза [2].

В последующем была разработана балльная шкала для прогнозирования степени риска развития несостоятельности ушитой культи бронха: низкого, среднего, высокого [2]. Для этого учитывались следующие факторы риска: объём оперативного вмешательства на основе сведений из историй болезни, эндотрахеальный наркоз, как фактор риска развития осложнений трахеобронхиального дерева, гемоплазмотрансфузия, как фактор риска развития гнойно-воспалительных осложнений вследствие травматизма оперативного вмешательства, гистологические свойства ткани удалённого бронха, характер внутрибольничной инфекции в стационаре, скорость оседания эритроцитов. Известно, что увеличение скорости оседания эритроцитов наблюдается при всех состояниях, сопровождающихся воспалением, деструкцией соединительной ткани, тканевым некрозом, иммунными нарушениями [2].

Необходимо отметить, что в первые сутки после операции врач располагает следующими данными, которые позволят предвидеть риск развития несостоятельности бронхиальной культи: объём и длительность оперативного вмешательства, особенности проведения эндотрахеального наркоза, показатель скорости оседания эритроцитов. Однако такие факторы риска, как гистологические данные, возбудители внутрибольничной инфекции, гемотрансфузии, выполняющиеся в течение всего послеоперационного периода, несомненно являются важными для прогнозирования. Однако сведения о них могут быть получены гораздо позже, что снижает их ценность в прогнозировании несостоятельности бронхиальной культи.

Таким образом, определены положительные свойства балльной шкалы в качестве метода оценки степени тяжести состояния больных гнойно – деструктивными заболеваниями лёгких на догоспитальном этапе или при первичном осмотре больных в клиничко – диагностическом центре, приёмном отделении лечебно – профилактического учреждения.

Поэтому для прогнозирования риска развития осложнений у больных с гнойно – деструктивными заболеваниями лёгких целесообразно использовать нейросетевое моделирование.

Исследование клинических, лабораторных, инструментальных и дополнительных данных у больных с гнойно – деструктивными заболеваниями лёгких позволило предложить четыре модели, влияющих на исход оперативного вмешательства. В основе первой модели, использовались показатели, по которым имелось достаточное количество наблюдений. Это следующие показатели: длительность операции, возраст, данные спирографии, микробиологические сведения о внутрибольничной инфекции, гемоглобин, лейкоциты, скорость оседания эритроцитов, общий билирубин, общий

белок, мочевины, глюкоза. В первой модели – одиннадцать клиническо – лабораторных показателей.

В основе второй модели использовались показатели, которые являлись наиболее информативными, так как оказывали существенное влияние на результирующую переменную, указывающую на отсутствие или наличие осложнения на множестве возможных исходов.

В третьей модели не были использованы гематологические показатели. В её структуре применены следующие клинические параметры: длительность операции, возраст, данные спирографии, микробиологические данные.

В четвёртую модель включены: гемоглобин, общий белок, длительность операции, возраст, данные спирографии.

Из-за того, что указанные выше наборы факторных признаков нами были предложены эмпирически, появилась необходимость определить формальную зависимость между факторными переменными и результирующей переменной, указывающей на наличие осложнения, с помощью множественного регрессионного анализа. В результате было установлено, что только в первой и во второй модели набора факторных признаков, факторные переменные оказывали влияние на результирующую переменную.

В связи с тем, что множественная регрессия позволяет выявить лишь наличие или отсутствие множественной линейной зависимости, был проведён формальный отбор признаков с помощью инструмента пошаговой регрессии – шаговый регрессионный анализ. Сущность метода шаговой регрессии заключается в последовательном включении факторов в уравнение регрессии и последующей проверке их значимости.

В результате применения процедуры шаговой регрессии было выяснено, что наибольшее влияние на результирующую переменную, наличие или отсутствие осложнения, оказывают две факторные переменные: продолжительность операции и скорость оседания эритроцитов.

Таким образом, в первой эмпирической модели имеется одиннадцать клиническо – лабораторных показателей, а во второй – 6. Однако такие факторные переменные, как продолжительность операции и скорость оседания эритроцитов представлены в обеих моделях. Как уже подчёркивалось, наборы факторных признаков первой и второй моделей влияют на прогноз возникновения осложнений.

Поэтому нами было отдано предпочтение шести клиническо – лабораторным показателям: длительность операции, возраст, данные спирографии, уровень гемоглобина, лейкоциты и скорость оседания эритроцитов.

Таким образом, эти данные являются параметрами нейросетевой информационной системы «Нейропредиктор». Однако нами был осуществлён выбор дополнительных качественных параметров для проектирования архитектуры нейросетей, их селекции и разработки информационной системы «Нейропредиктор» риска развития гнойно-воспалительных осложнений в хирургии. Нами были изучены формально установленные показатели, полученные врачами экспертами предметной области на основе практического опыта, медико-статистическом и регрессионном анализе переменных множества медицинских данных об осложнениях гнойно-воспалительного характера и развития несостоятельности ушитой бронхиальной культи, в том числе и применяемые в балльной шкале оценки состояния больных гнойно-деструктивными заболеваниями лёгких. Важно отметить, что с целью вовлечения и активного участия врача в процессе и результатах нейросетевого моделирования, был введён параметр «клиническая оценка тяжести состояния больного». Однако необходимо объяснить почему не были приняты в качестве параметров прогнозирования в информационную систему «Нейропредиктор» следующие показатели: микробиологические возбудители внутрибольничной инфекции, гистологические свойства бронха по линии его резекции, особенности выполнения эндотрахеального наркоза. Возбудители внутрибольничной инфекции сопровождают течение послеоперационного периода подавляющего

большинства больных гнойно-деструктивными заболеваниями лёгких. Гистологические свойства ткани удалённого бронха по линии его резекции не позволяют утверждать, из-за отсутствия специальных морфологических исследований, об их роли в развитии несостоятельности и гнойно-воспалительных осложнений у данной категории больных. Эндотрахеальный наркоз больным с гнойно-деструктивными заболеваниями лёгких в областной клинической больнице выполняется двумя специально подготовленными анестезиологами, имеющими высшие квалификационные категории и стаж практической работы свыше двадцати лет. Поэтому осложнений наркоза в изучаемой когорте больных не было.

Таким образом, были подготовлены параметры для нейросетевого моделирования. Учитывая опыт работы с анализом медицинских данных при прогнозировании осложнений раннего послеоперационного периода методом нейронных сетей, было решено не использовать весь набор переменных для обучения, так как чем больше данных, тем сложнее обучить нейросеть. Но даже, если и удастся получить нейросетевую модель, однако скажется эффект переобучения. Этот феномен объясняется тем, что нейросеть плохо распознаёт вновь поступающие данные, что отражается на результативности прогнозирования. Поэтому нами было предложено применить квантование данных. Одним из известных преобразований, используемых при подготовке данных к нейросетевому анализу, является квантование. Квантование подразумевает разбиение диапазона значений числового признака на заданное конечное число интервалов. Затем, полученным интервалам присваиваются номера, именуемые уровнями квантования. Каждое значение заменяется номером интервала квантования, в который попало данное значение. Квантование позволяет представлять и хранить данные в более компактном и защищённом от искажений виде. Важным аспектом является выбор числа интервалов. В результате квантования осуществляется переход от точных данных к некоторому набору интервалов и при этом неизбежна потеря информации. Следовательно, чем больше используется интервалов, тем точнее реализуется представление исходных значений. Квантование упрощает алгоритм обучения нейронной сети. Нами осуществлялось квантование следующих данных: длительность операции, объём гемоплазмотрансфузий, скорость оседания эритроцитов, возраст больных, уровень гемоглобина, лейкоциты периферической крови. Для качественных переменных: перечень операций, данные спирографии, клиническая оценка тяжести состояния хирургических больных с гнойно-деструктивными заболеваниями лёгких, была разработана система кодирования медицинских данных.

Таким образом, квантованные и кодированные данные впоследствии использовались для экспериментов с нейронной сетью: персептроном и нейронными сетями с сигмоидальной функцией активации, гиперболическим тангенсом. Использовался пакет Matlab.

Персептрон – однослойная нейросеть с пороговой функцией активации. Он применяется для разделения показателей входных переменных на множества. Применение однослойного персептрона позволило прогнозировать риск развития осложнений у больных с гнойно-деструктивными заболеваниями лёгких с достоверностью 75 %.

Далее были применены нейронные сети с одним и двумя слоями нейронов. Нейросеть, состоящая из одного нейрона с сигмоидальной функцией активации, логистической функцией, прогнозирует осложнения с достоверностью 85 %. Многослойная сигмоидальная нейросеть, состоящая из одного нейрона в первом слое и одного во втором, осуществляет прогноз с достоверностью 90 %. Дальнейшие эксперименты с усложнением структуры нейросети путём увеличения количества нейронов первого слоя, не приводят к улучшению её работы.

Таким образом, для создания нейросетевой информационной системы прогнозирования гнойно-воспалительных осложнений «Нейропредиктор» были

проведены статистический анализ исходных данных, выбор критериев для построения нейросетевой модели, а также проведены эксперименты по подбору типа и архитектуры нейронной сети для осуществления прогноза. Применялось квантование входных данных и их кодирование для улучшения качества работы нейронной сети.

В дальнейшем нами исследовались нейронные сети для решения задачи прогнозирования кровопотери у больных с гнойно-деструктивными заболеваниями лёгких с учётом дооперационного показателя гемоглобина, длительности операции, объёма перелитых компонентов крови. Нейросетевое прогнозирование кровопотери было сформулировано как задача регрессии, которая решалась с помощью следующих нейросетей: многослойного персептрона, радиально – базисных нейросетей, обобщённо – регрессионных и линейных нейросетей. С указанными нейросетями были проведены компьютерные эксперименты. Для каждой переменной были вычислены исходные статистические величины. С помощью экспериментов в пакете Matlab подбиралась оптимальная архитектура многослойной сигмоидальной нейросети. Испытания проводились на трёхслойной и четырёхслойной нейросетях, имеющих входной, скрытые и выходной слои. Количество нейронов входного и выходного слоёв определялось количеством входных и выходных переменных. Эксперименты были начаты с архитектуры 3 – 2 – 1, то есть три нейрона располагались во входном слое, два – в скрытом и один в выходном. Нейросети с количеством скрытых нейронов от десяти до двадцати дают сопоставимые результаты.

В ходе нейросетевых экспериментов было установлено, что лучшие результаты нейросетевого прогнозирования кровопотери достигаются с помощью нейросети, имеющей архитектуру 3 – 10 – 1, то есть с тремя нейронами во входном слое, с десятью – в скрытом, одним – в выходном. Достоверность прогнозирования кровопотери составила 95 %.

Таким образом, нейросетевое прогнозирование кровопотери до операции по трём клинико-лабораторным показателям соответствует данным лабораторной диагностики в послеоперационном периоде.

Необходимо ещё раз отметить, что в нейросетевой информационной системе «Нейропредиктор» большая роль отводится клинической оценке состояния больных. На догоспитальном этапе была предложена балльная шкала, но она не позволяет осуществлять проспективный прогноз осложнений. Поэтому важной задачей является создание нейросетевых информационных систем прогнозирования риска развития полиорганной недостаточности: почечной и печёночной у больных гнойно-деструктивными заболеваниями лёгких. Полученные сведения помогут поддержать решение врача в объективизации клинической оценки состояния больных гнойно-деструктивными заболеваниями лёгких. Поэтому нами были разработаны информационные системы диагностики синдрома эндогенной интоксикации, синдрома эндогенной интоксикации с почечной дисфункцией, печёночной недостаточности на основе универсальных гематологических показателей.

Таким образом, создан комплекс нейросетевых информационных программ диагностики и прогнозирования осложнений у больных гнойно – деструктивными заболеваниями лёгких.

Список литературы

1. Гринблат А.И. Практические вопросы лёгочной хирургии. – СПб.: Издательство «Лань», 1999. - 96 с.
2. Соломаха А.А. Метод балльной оценки тяжести состояния хирургических больных с гнойно-деструктивными заболеваниями лёгких // Вестник службы крови России. - 2011. - № 3. – С. 36 – 40.
3. Французов В.Н. Хирургические инфекции – проблема современной медицины // Вестник Национального медико-хирургического Центра им. Н.И. Пирогова. - 2006. - № 1. – С. 51 – 54.

LOCALITY-PRESERVING TRANSFORMATIONS FOR DATA DIMENSIONALITY REDUCTION

Sergey A. Subbotin

Zaporizhzhya National Technical University, Zaporizhzhya, Ukraine, subbotin@zntu.edu.ua

1. Introduction

The actual problem in computational diagnosis and pattern recognition is data dimensionality reduction, which usually performed by feature selection [1]. As an alternative to this way the sample selection [2] can be used. Unfortunately, it involves necessity of computation and using a distance matrix in N -dimensional feature space, that causes a combinatorial complexity of large data processing. The purpose of this work is the development of rapid transformations from a multidimensional feature space to a one-dimensional axis, that can be used for a sample selection.

Suppose we have an initial (original) sample $X = \langle x, y \rangle$ the set of S precedents describing dependence $y(x)$, $x = \{x^s\}$, $y = \{y^s\}$, $s = 1, 2, \dots, S$, characterized by a set of N input features $\{x_j\}$, $j = 1, 2, \dots, N$, where j is the number of feature, and an output feature is y . Every s -th precedent can be represented as $\langle x^s, y^s \rangle$, $x^s = \{x_j^s\}$, where x_j^s is the value of j -th input feature and y^s is the value of output feature for the s -th precedent (instance) of the sample, $y^s \in \{1, 2, \dots, K\}$, where K is the number of classes, $K > 1$.

Then the problem of the sample X dimensionality reduction can be formally represented as follows: find a transformation $H: X \rightarrow I$, which for each instance $x_j^s = \{x_j\}$ determine the coordinate I^s on the generalized axis I and thus provides a mapping of instances of different classes to the different intervals of the generalized axis.

2. Transformations to the generalized axis

For large-scale problems it is advisable to ensure the creation of such transformations, which would allow the mapping of individual instances without loading of whole initial sample, as well as taking into account the feature informativity in the process of transforming and to provide a generalization of data. To ensure the generalization of close located data points (instances) we propose to replace feature values x_j^s to numbers of feature value interval $\hat{x}_j^s$. For this we need previously to discretize the features by partitioning them into intervals of values. To ensure the generalization of close located data points (instances) we propose to replace feature values to numbers of feature value interval. For this we need previously to discretize the features by partitioning them into intervals of values. For the mapping of instances from the original multi-dimensional feature space to the one-dimensional generalized axis is suggested to use the following transformations.

Transformation 1. For each number of interval of j -th feature get it binary representation (binary numbers padded with zeros from the left to c_j – the number of digits in k_j). Set the coordinate of s -th instance on the generalized axis $I^s = 0$, set the position (bit) number of generalized axis coordinate $p = 1$. Going by the feature numbers j in descending

order of their rank and by the group of digits in the interval number $c = 1, 2, \dots, c_j$ perform in a cycle: if $p \leq d$, where d is a number of bits in a computer bit grid, then record at p -th position (with numbering from left) of the binary representation of a generalized feature I^s the c -th position value (with numbering from left) of interval number, in which the s -th instance hit on the j -th feature, and set: $p = p + 1$. As a result, we will obtain a generalized axis coordinate of instance with the implicit ranking and selection of features.

Transformation 2. It is an alternative format of constructing a generalized feature for transformation 1. If the total number of bits to represent interval numbers of all features $c_j k_j N$ does not exceed the number of bits in a binary bit grid d when the values c_j are equal for all features: for each interval number of j -th feature obtain its binary representation (binary numbers padded with zeros from the left to c_j – the number of digits in k_j) set the coordinate of s -th instance on the generalized axis $I^s = 0$, set the position number of coordinate on a generalized axis $p = 1$; looking in a cycle on a group of digits in the interval number $c = 1, 2, \dots, c_j$ and on feature numbers j in the descending order of their ranks: put to the p -th bit position (numbering from the left) of the binary representation of the generalized feature I^s the c -th bit (numbering from the left) of interval number, in which the s -th instance hits on the j -th feature and set: $p = p + 1$. As a result, we obtain the generalized axis coordinate with implicit ranking of features.

Transformation 3. The above-described transformations provide mapping to the discrete generalized axis. If the total number of bits to represent numbers of all feature intervals exceeds the number of bits in a bit grid of computer, it is possible to use a transformation to the generalized real axis with partial information loose: add to the real coordinate on generalized feature I^s the c -th bit (numbering from the left) of interval number, in which the s -th instance hits on the j -th feature:

$$I^s = \sum_{j=1}^N \frac{w_j \hat{x}_j^s}{r_j k_j}, \quad w_j = \frac{1}{k_j} \sum_{k=1}^{k_j} w_{j,k}, \quad w_{j,k} = \left\{ \frac{\max_{q=1,2,\dots,K} \{S_{j,k}^q\}}{S_{j,k}} \middle| S_{j,k} > 0 \right\}, \quad S_{j,k} = \sum_{q=1}^K S_{j,k}^q,$$

where $S_{j,k}^q$ is a number of q -th class instances located in the k -th interval of j -th feature, r_j is a rank of j -th feature (the number of j -th feature in decreasing order of feature importance).

Transformation 4. Define the distance from the s -th instance to the unit vector in the normalized coordinate system: $d^s = \sqrt{\sum_{j=1}^N (\hat{x}_j^s - 1)^2}$, and the angle between the instance as a

vector and the unit vector: $\varphi^s = \arccos \left(\frac{\sum_{j=1}^N \hat{x}_j^s \left(N \sum_{j=1}^N (\hat{x}_j^s)^2 \right)^{-1/2}}{1} \right)$. Thus we map the s -th instance

from the N -dimensional space into two-dimensional space. Next for coordinates of s -th instance in formed two-dimensional space by analogy with the first transformation obtain coordinate of s -th instance on the generalized axis I^s .

3. Characteristics of transformations to the generalized axis

Entered above transformations are encouraged to use the following characteristics of instance mapping process: t^s is the time of transforming of one instance from the original feature space to the generalized axis for the sequential computations, m^s is the computer memory volume used by the transformation method for processing one instance, λ is the number of adjustable parameters of transformation needed for its implementation, t is the time of calculation of transformation parameters based on the training sample, m the computer memory volume used to calculate the transformation parameters on the basis of training sample.

Situations where several instances have equal coordinates may occur in the original and in the synthesized feature spaces. Such situations are called collisions. Under the collision point we will understand the point in the feature space, in which there is a collision.

The collision is quite admissible and even desirable in problems of automatic classification on condition that all instances located at the point of collision belongs to the same class. However, if the instances located at the point of collision, belongs to different classes, the used feature set does not provide a good separability of instances.

Denote the set of points of collision $\{g_v\}, v=1,2,\dots,V$, where g_v is a set of instances belonging to a v -th point of collision, V is the number of points of collision, which obviously can not exceed $0,5S$.

To estimate the quality of the results of considered transformations we propose to use the following indicators.

The number of points of collisions in which instances belongs to different classes, after the transformation of the sample to the generalized axis can be defined as:

$E_{<I,y>}^* = \sum_{v=1}^V \{1 | \exists s, p=1,2,\dots,S, p \neq s: I^s \in g_v, I^p \in g_v, I^s = I^p, y^s \neq y^p\}$. This indicator in the best case will be equal to zero when there is no collision points, and in the worst case it maximum value will not exceed $0,5S$.

The probability estimation (frequency) of the collision points in which instances belonging to different classes, after the transformation of the sample to the generalized axis

can be expressed by the formula: $P_{<I,y>}^* = \frac{2E_{<I,y>}^*}{S}$.

The corrected number of points of collisions in which instances belong to different classes, after the transformation of the sample to the generalized axis is defined as:

$E_{<I,y>}^{*'} = E_{<I,y>}^* - E_{<x,y>}^*$, where the number of collision points in which the instances belongs to different classes in the initial sample: $E_{<x,y>}^* = \sum_{v=1}^V \{1 | \exists s, p=1,2,\dots,S, p \neq s: x^s \in g_v, x^p \in g_v, y^s \neq y^p, \forall j=1,2,\dots,N: x_j^s = x_j^p\}$. The indicator $E_{<I,y>}^{*'}$

more accurately characterizes the quality of transformation to the generalized axis because it eliminates the errors present in the sample. In the best case it will be equal to zero when there is no collisions, and in the worst case it maximum value will not exceed $0,5S$.

The corrected probability estimation (frequency) of the collision points in which the instances belong to different classes after the sample transformation to the generalized axis can be obtained by the formula: $P_{<I,y>}^* = \frac{2E_{<I,y>}^*}{S}$.

The total number of instances in the collision points in which the instances belong to different classes after the sample transformation to the generalized axis is suggested to calculate by the formula:

$E_{<I,y>}^\Sigma = \sum_{v=1}^V \left\{ g_v \mid \exists s, p = 1, 2, \dots, S, p \neq s : I^s \in g_v, I^p \in g_v, I^s = I^p, y^s \neq y^p \right\}$. The more will be value of this indicator, the worse separability of instances on the generalized axis. In the best case it will be equal to zero and in the worst case it will not exceed the number of instances in the sample S .

The probability estimation of instance hitting to the collision point in which instances belong to different classes after the sample transformation to the generalized axis can be obtained by the formula: $P_{<I,y>}^\Sigma = E_{<I,y>}^\Sigma / S$.

The total number of instances in the collision points of the initial sample in which the instances belong to different classes it is proposed to define as:

$E_{<x,y>}^\Sigma = \sum_{v=1}^V \left\{ g_v \mid \exists s, p = 1, 2, \dots, S, p \neq s : x^s \in g_v, x^p \in g_v, y^s \neq y^p, \forall j = 1, 2, \dots, N : x_j^s = x_j^p \right\}$. The more will be the value of this indicator, the worse the separability of instances of the initial sample will be. In the best case it will be equal to zero and in the worst case it not exceed the number of instances in the sample S .

The probability estimation of instance collision in the sample in which instances belong to different classes can be obtained from the formula: $P_{<x,y>}^\Sigma = E_{<x,y>}^\Sigma / S$.

The number of pairwise collision of instances of different classes after the sample transformation to the generalized axis is proposed to determine as:

$E_{<I,y>} = \sum_{s=1}^S \sum_{p=s+1}^S \{ y^s \neq y^p \mid I^s = I^p \}$. In the best case, this indicator is zero when there is no any collision, and in the worst case its value will not exceed $S(S-1)$.

The probability estimation (frequency) of pairwise collision of instances of different classes after the sample transformation to the generalized axis can be calculated as follows:

$$P_{<I,y>} = E_{<I,y>} / (S^2 - S).$$

The corrected number of pairwise collision of instances of different classes after the transformation of training and (or) test sample to the generalized axis is proposed to determine as: $E'_{<I,y>} = E_{<I,y>} - E_{<x,y>}$, where $E_{<x,y>}$ is a number of pairwise collision of instances of different classes in the original sample:

$$E_{<x,y>} = \sum_{s=1}^S \sum_{p=s+1}^S \{ y^s \neq y^p \mid \forall j = 1, 2, \dots, N : x_j^s = x_j^p \}.$$

This indicator $E'_{<I,y>}$ in comparison with the previous indicator more accurately characterizes the quality of the transformation to the generalized axis, because it eliminates the errors present in the original sample. In the best

case, it would be equal to zero when there is no any collision, and at worst case, it maximum value will not exceed $S(S-1)$.

The corrected probability estimation (frequency) of pairwise collisions of instances of different classes after sample transformation to the generalized axis can be defined by the formula: $P'_{\langle I, y \rangle} = E'_{\langle I, y \rangle} / (S^2 - S)$.

The average number of clusters per class on a generalized axis can be calculated by the formula $\bar{k} = \frac{k}{K}$, where k is a number of clusters of different classes on a generalized axis. To determine k , we need order the instances $\langle I^s, y^s \rangle$ in ascending order on the generalized axis. Then, looking from left to right, we need to identify clusters – the intervals of one-dimensional axis, all instances of each of which belong to only one class. The less will be the number of such clusters, the simply is partition of generalized axis. In the best case when the classes are compact, i.e. $k = K$, this indicator is equal to one. The more will be value of this indicator, the worse the separability of instances will be on the generalized axis. In the worst case where each instance falls into a single cluster its value will be $\bar{k} = S / K$.

The minimum distance between instances of different classes on the generalized axis is offered to determine by the formula: $R'_{\min} = \min_{\substack{s=1, \dots, S; \\ p=s+1, \dots, S}} \{ |I^s - I^p| \mid y^s \neq y^p \}$. The more will be value of this ratio, the better classes will be separated on the generalized axis.

The maximum distance between instances of one class on the generalized axis is offered to determine by the formula: $R'_{\max} = \max_{\substack{s=1, \dots, S; \\ p=s+1, \dots, S}} \{ |I^s - I^p| \mid y^s = y^p \}$. The less will be this indicator value, the more compact instances of each class will be positioned on the generalized axes.

The average ratio of distances on the generalized axis and in the original feature space is proposed to calculate by the formula:

$$\bar{\Delta} = \frac{R_{\max}}{0,5S(S-1)R_{\max}^*} \sum_{s=1}^S \sum_{p=s+1}^S \left\{ \frac{|I^s - I^p|}{R(x^s, x^p)} \mid R(x^s, x^p) > 0 \right\},$$

$$R_{\max}^* = \max_{\substack{s=1, \dots, S; \\ p=s+1, \dots, S}} \{ |I^s - I^p| \}, R_{\max} = \max_{\substack{s=1, \dots, S; \\ p=s+1, \dots, S}} \{ R(x^s, x^p) \}, R(x^s, x^p) = \sqrt{\sum_{j=1}^N (x_j^s - x_j^p)^2}.$$

The more will be value of this indicator, the better on the average the transformation on the generalized axis reflects location of instances in the original space and features the better separability of instances on the generalized axis;

Average of the relative distance products on the generalized axis and in the original feature space:

$$\Delta = \frac{\sum_{s=1}^S \sum_{p=s+1}^S |I^s - I^p| R(x^s, x^p)}{0,5S(S-1)R_{\max}^* R_{\max}}.$$

This indicator will vary from zero to one: The more will be its value, the better on the average the transformation on the generalized axis reflects the location of instances in the original feature space.

The indicator of generalized axis feasibility of establishing: $G = k^{-1} \min_{j=1,2,\dots,N} \{k_{\langle x_j, y \rangle}\}$,

where $k_{\langle x_j, y \rangle}$ is the number of intervals of different classes on the axis of feature x_j .

This indicator in the best case will be equal to S/K , and in the worst case will be equal to K/S . If this indicator will be greater than one, the use of the generalized axis will be feasible, otherwise it can be replaced with the original feature, characterized by the smallest number of intervals of different classes.

4. The comparison criteria of generalized axis transformations

On the basis of the indicators characterizing the basic properties of on the generalized axis transformations introduced in the previous section it is possible to determine the criteria for comparison, the criteria for performing and criteria for evaluating the quality of the results of transformations.

The criteria for evaluation of the transformation process is proposed to define as the following: the combined criterion of the minimum of time and memory on the instance transformation $F_1 = t^s m^s \rightarrow \min$; the combined criterion of the minimum of time and memory to determine the transformation parameters for the training sample $F_2 = \lambda t m \rightarrow \min$; the integral criterion: $F_3 = t^s m^s + \lambda S^{-1} t m \rightarrow \min$.

The criteria for evaluating the quality of results of transformations: the criterion of the minimum of probability of instance group collisions: $F_4 = P'_{\langle I, y \rangle} \rightarrow \min$; the criterion of the minimum of probability of instance pair collisions: $F_5 = P^{*'}_{\langle I, y \rangle} \rightarrow \min$; the combined criterion of the minimum probability of pair and group collisions: $F_6 = \frac{P'_{\langle I, y \rangle} + P^{*'}_{\langle I, y \rangle}}{2} \rightarrow \min$;

– the maximum of class compactness-separability: $F_7 = \bar{k} \rightarrow \min$; the integral criterion of minimum of collisions-compactness-separability of classes: $F_8 = \frac{\bar{k}}{2} (P'_{\langle I, y \rangle} + P^{*'}_{\langle I, y \rangle}) \rightarrow \min$, $\bar{k} > 0$; the integral criterion of minimum of collision-maximum of compactness-separability of classes and maximum of average of relative distances products on the generalized axis and in the original feature space: $F_9 = \frac{\bar{k} (P'_{\langle I, y \rangle} + P^{*'}_{\langle I, y \rangle})}{1 + \Delta e^{-\bar{\Delta} + 1}} \rightarrow \min$; the

integral criterion of the minimum of collisions-maximum of a generalized axis establishing feasibility-compactness-separability of classes and the maximum of average of relative distances products on the generalized axis and in the original feature space:

$$F_{10} = \frac{(P'_{\langle I, y \rangle} + P^{*'}_{\langle I, y \rangle})}{G + \Delta e^{-\bar{\Delta} + 1}} \rightarrow \min.$$

5. Experiments and results

The proposed transformations to the generalized axis have been implemented as software and experimentally studied in practical problem solving of technical and medical diagnosis, and of automatic classification [3].

The conducted experiments confirmed the efficiency and the practical suitability of the developed mathematical tools. The experiments have shown that the proposed transformations allow to significantly reduce the data sample dimensionality. The Table show

the best transformations for different practical tasks according to proposed criteria. The proposed transformations can be recommended for use in the construction of diagnostic and recognizing models by precedents, as well as for the formation of the training samples from the source samples of large volume.

Table

The fragment of the experimental results to study the transformations on generalized axis

Task characteristics	Task			
	Gas-turbine air-engine blade diagnosis	Chronic obstructive bronchitis diagnosis	Agricultural plant recognition on the remote sensing data	Fisher Iris classification
S	32	205	3226	150
N	513	28	256	4
K	2	2	3	3
Best transformation number	2	1	4	1
F_1	4.2013	0.14001	0.079613	0.034168
F_2	$1.1209 \cdot 10^8$	$8.6207 \cdot 10^5$	$3.1336 \cdot 10^{10}$	$0.26654 \cdot 10^5$
F_3	$3.5028 \cdot 10^6$	4205.4	$9.7134 \cdot 10^6$	177.73
F_4	0.0010081	0	0	0.00040268
F_5	0.0625	0	0	0.013333
F_6	0.031754	0	0	0.006868
F_7	7.5	36	591	3.6667
F_8	0.23816	0	0	0.025183
F_9	0.42786	0	0	0.041701
F_{10}	0.20274	0	0	0.011373

The actual problem of the development of mathematical support for data dimensionality reduction has been solved in the paper.

The scientific novelty of results consists in that the set of rapid transformations from the original multi-dimensional space into one-dimensional axis was firstly proposed. The proposed transformations provide a solution both the problem of constructing of artificial features (feature extraction), and the problem selection of the most significant features (feature selection).

References

1. Jensen R. Computational intelligence and feature selection: rough and fuzzy approaches / R. Jensen, Q. Shen. – Hoboken: John Wiley & Sons, 2008. – 339 p.
2. Subbotin S. A. Methods of sampling based on exhaustive and evolutionary search // Automatic Control and Computer Sciences. – 2013. – Vol. 47, № 3. – P. 113-121.
3. Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла авиационных двигателей : монография / [А. В. Богуслаев, Ал. А. Олейник, Ан. А. Олейник, Д. В. Павленко, С. А. Субботин] ; под ред. Д. В. Павленко, С. А. Субботина. – Запорожье : ОАО "Мотор Сич", 2009. – 468 с.

АССОЦИАТИВНАЯ ПАМЯТЬ НА МЕМРИСТОРНОМ КРОССБАРЕ

М.С. Тарков^{1,2}, М.И. Осипов³

¹Институт физики полупроводников СО РАН им. А.В. Ржанова,
лаб. материаловедения кремния, tarkov@isp.nsc.ru

²Новосибирский государственный университет, каф. вычислительных систем

³Институт систем информатики СО РАН, inq1201@mail.ru

Введение

Искусственная нейронная сеть обычно использует матрицу весовых коэффициентов для представления множества синапсов слоя нейронов. Соответственно вычисление активации слоя нейронов можно рассматривать как умножение этой матрицы весов на вектор входных сигналов слоя. Аппаратная реализация нейронной сети требует много памяти для хранения матрицы весов слоя нейронов и является дорогостоящей.

Решение этой проблемы упрощается при использовании в качестве ячейки памяти устройства, называемого мемристором. Мемристор был предсказан теоретически в 1971 году Леоном Чуа [1]. Первую физическую реализацию мемристора продемонстрировала в 2008 году лаборатория фирмы Hewlett Packard в виде тонкопленочной структуры TiO_2 [2]. В России первый мемристор на основе TiO_2 получен в 2012 году в Тюменском государственном университете [3]. Мемристор имеет много достоинств, таких как энергонезависимость хранения информации, малое потребление энергии, высокая плотность интеграции и замечательная масштабируемость. Уникальная способность сохранять следы возбуждения устройства делает его идеальным кандидатом для реализации синапсов в электронных нейронных сетях [4].

Мемристорный кроссбар

Мемристор ведет себя подобно синапсу: он «запоминает» полный электрический заряд, прошедший через него [5]. Память, основанная на мемристорах, может достигать очень высокой степени интеграции 100 Gbits/cm^2 , в несколько раз более высокой, чем на основе технологии флэш-памяти [6]. Эти уникальные свойства делают мемристор многообещающим устройством для создания массово-параллельных нейроморфных систем [7-9].




Рис. 1. Структура мемристора: D – зона низкого сопротивления, U – зона высокого сопротивления

Сопротивление мемристора (memristance) (рис. 1) может быть представлено [10] как

$$M(p) = p \cdot R_{on} + (1 - p) \cdot R_{off}, \quad (1)$$

где $0 \leq p \leq 1$ положение фронта примеси относительно полной толщины h пленки TiO_2 , R_{on} – минимальное сопротивление мемристора, R_{off} – максимальное сопротивление мемристора. Когда на мемристор подается напряжение V выше некоторого порога V_{th} , его сопротивление уменьшается за счет расширения примесной зоны D , имеющей низкое сопротивление, и сокращения зоны U чистого окисла, имеющей высокое сопротивление. Соответственно сопротивление мемристора возрастает при подаче напряжения V ниже $-V_{th}$ за счет сокращения зоны D и расширения зоны U . После отключения напряжения текущее сопротивление мемристора сохраняется.

Скорость движения фронта примеси при $V(t) > V_{th}$ (сопротивление мемристора убывает) определяется уравнением

$$\frac{dp}{dt} = \mu_v \cdot \frac{R_{on}}{h^2} \cdot \frac{V(t) - V_{th}}{M(p)}, \quad (2)$$

а при $V(t) < -V_{th}$ – уравнением

$$\frac{dp}{dt} = \mu_v \cdot \frac{R_{on}}{h^2} \cdot \frac{V(t) + V_{th}}{M(p)}. \quad (3)$$

Здесь μ_v – подвижность примеси, h – полная толщина пленки мемристора, $V(t)$ – текущее значения напряжения на мемристоре, V_{th} – пороговое значение напряжения.

Настройка мемристора на требуемый уровень сопротивления M_d зависит от соотношения между M_d и начальным значением M_0 сопротивления мемристора. Настройка осуществляется путем подачи на мемристор в течение отрезка времени τ постоянного напряжения $V > V_{th}$ при $M_0 > M_d$ или напряжения $V < -V_{th}$ при $M_0 < M_d$. Решая совместно уравнения (1) и (2) или (1) и (3), получаем требуемое значение времени

$$\tau = \begin{cases} \frac{M_0^2 - M_d^2}{2k(V - V_{th})}, & V > V_{th}, \\ \frac{M_0^2 - M_d^2}{2k(V + V_{th})}, & V < -V_{th}, \end{cases} \quad (4)$$

где $k = \mu_v \frac{R_{off}}{h^2} (R_{off} - R_{on})$.




Рис. 2. Слой нейронов с матрицей весов на мемристорах

На рис. 2 представлен слой нейронов (нейроны обозначены треугольниками) с матрицей весовых коэффициентов на мемристорах, называемой мемристорным кроссбаром, который является типичной структурой мемристорной памяти. Он содержит мемристор на каждом пересечении горизонтальных и вертикальных проводников. Мемристорный кроссбар интересен для реализации матриц соединений в нейронных сетях, поскольку он может обеспечить большое число сигнальных связей и вычислить взвешенную комбинацию входных сигналов. На горизонтальные шины кроссбара подаются компоненты вектора входных сигналов слоя. Каждая вертикальная шина кроссбара позволяет вычислить активацию для одного из нейронов слоя.

В данной работе предложена модель аппаратной реализации нейронной WTA (“Winner takes all”)-сети, которая реализует ассоциативную память и основана на использовании кроссбара. Предусмотрена процедура обучения сети, реализованная аппаратно, в связи с чем синапс помимо мемристора содержит элемент управления на КМОП-транзисторе для контроля тока через мемристор.

WTA-сеть

Работа слоя WTA-сети описывается выражением (5), где w_i – вектор весов i -го нейрона, $i = 1, \dots, p$, f – функция активации нейрона, x – вектор входных сигналов слоя нейронов, y_i – выходной сигнал i -го нейрона. Предполагается, что $x_j, j = 1, \dots, N$ – сигналы, образованные входным образом, $x_0 = 1$, w_{i0} – порог i -го нейрона.

$$y_i = f(a_i), a_i = \sum_{j=0}^N w_{ij} x_j. \quad (5)$$

Согласно принципу WTA, вывод о принадлежности тестового образца к какому-либо классу делается, исходя из номера нейрона, значение активации которого максимально.




Рис. 3. Изображения символов “Т”, “Х” и “L”

В качестве запоминаемых в WTA-сети образов используются бинарные изображения размера 8×8 пикселей (примеры изображений приведены на рис. 3). Черным пикселям соответствует значение «1» во входном векторе и вес $W_{\max}$ в кроссбаре, а белым «-1» вес $W_{\min}$. Пороги $w_{i0} = (m-1)W_{\max} - (n+1)W_{\min}$, $i = 1, \dots, 3$, где m – количество черных пикселей в образце, n – количество белых пикселей, $W_{\max} = 1/M_{\min}$, $W_{\min} = 1/M_{\max}$, $M_{\min}$ и $M_{\max}$ – минимальное и максимальное сопротивления мемристора. Размер кроссбара, реализующего матрицу весов для сети, запоминающей m эталонных изображений, равен $m \times (N+1)$, $N = 64$ – размерность изображения.

Аппаратная модель сети WTA и ее обучение

Использование мемристора дает возможность устанавливать вес синапса в процессе обучения сети. Напряжение, поданное на затвор КМОП-транзистора, открывает его и позволяет току идти через мемристор, тем самым меняя его сопротивление.

WTA-сеть, реализованная в симуляторе LTspice IV [11] с использованием интерфейса на языке MATLAB [12, 13], представлена на рис. 4. Транзисторы Neuron1, Neuron2, Neuron3 реализуют функцию активации f . Каждая строка синапсов кроссбара совместно с транзистором, реализующим функцию активации, образует нейрон WTA-сети и имеет отдельный управляющий источник напряжения. Перед обучением (настройкой) мемристоров производится замер их сопротивлений. Для этого на каждый мемристор кроссбара подается короткий импульс (1 нсек), не меняющий сопротивление мемристора.




Рис. 4. WTA-сеть для хранения эталонов рис. 3.

После получения текущих значений сопротивлений мемристоров при заданных напряжениях $V1 \div V65$ вычисляются согласно (4) значения длительностей t импульсов, необходимых для достижения требуемых сопротивлений $M_{\min}$ и $M_{\max}$ мемристоров.

В реальных мемристорах за счет сильных электрических полей, присутствующих в наномасштабах, проявляются сильные нелинейные эффекты в транспорте ионов. Для учета этих эффектов в модели мемристора [14, 15] используется оконная функция, на которую умножается правая часть уравнений (2) и (3). В результате на вольтамперной характеристике мемристора появляются достаточно резкие фронты, соответствующие переходу от состояния с низкой проводимостью к состоянию с высокой проводимостью и обратно. Поэтому использование выражений (4) возможно не на всем диапазоне 100 Ом $\div$ 16 кОм значений сопротивления мемристора [14]. Считая начальные значения сопротивлений мемристоров равномерно распределенными на интервале от 1 кОм до 15 кОм, в качестве целевых значений сопротивлений выбираем близкие к центру вышеуказанного интервала ($M_{\min} = 6$ кОм, $M_{\max} = 9$ кОм), чтобы уменьшить ошибки настройки. Эксперименты показали, что среднее время настройки мемристора (время импульса напряжения $V=5$ вольт) составляет 0,0356 сек. (пороговое напряжение V_{th} полагаем равным нулю), средняя ошибка настройки равна 3,692 Ом. Максимальное значение ошибки составляет 57 Ом, то есть менее 1% от $M_{\min}$.

Обучение производится последовательно по строкам кроссбара (рис. 4). Сначала напряжение подается на затворы транзисторов синапсов первой строки (мемристоры M11÷M165), который соответствует первому запоминаемому образу. На мемристоры подаются импульсы с заданным напряжением V в течение вычисленного времени t , чтобы сопротивление мемристоров достигло целевых значений. При этом значения сопротивлений синапсов в остальных рядах остается неизменным, так как напряжение на затворы их транзисторов не подается. Аналогичная процедура производится для всех остальных строк кроссбара. В итоге все мемристоры кроссбара будут иметь сопротивления $M_{\min}$ или $M_{\max}$ в соответствии с содержанием запоминаемых образов.

Настройка мемристоров производится путем подачи напряжений от источников hold1, hold2 и hold3 на затворы соответствующих транзисторов, с последующей подачей напряжений V1÷V65 на соответствующие мемристоры (рис. 4). Для устранения побочных токов при настройке мемристоров производится заземление горизонтальных шин кроссбара транзисторами NG0, NG1, NG2 путем подачи на их затворы напряжения Vread. После завершения процесса обучения необходимо сохранить состояния мемристоров в файле для последующего тестирования настроенной (обученной) сети. Для этого производится замер измененных сопротивлений мемристоров так же, как и на начальном этапе.

На этапе тестирования сети входные сигналы задаются короткими импульсами напряжения (1 нсек.) Все напряжения одинаковы по модулю (5 вольт), знак напряжения зависит от цвета пикселя: черному соответствует положительное напряжение, белому – отрицательное. На пороговый вход подается положительное напряжение. В режиме тестирования (распознавания) все транзисторы кроссбара открыты (кроме заземляющих транзисторов NG0, NG1, NG2).




Рис. 5. Зависимость качества распознавания от уровня шума

В качестве тестовых данных использовались запоминаемые образцы рис. 3, подвергшиеся зашумлению – инвертированию заданного количества случайных пикселей. Эксперименты производились с образцами, уровень шума на которых составляет от 5% до 40%. Результаты тестирования представлены на рис. 5.

Результаты тестирования показывают, что уровень зашумления в 5% не влияет на качество распознавания. Средний показатель уровня распознавания при зашумлении от 10% до 15% составляет около 95%, а при уровне шума в 20% этот показатель снижается лишь до 90%. При увеличении уровня шума до 40% уровень распознавания равномерно падает до 60%-50%.

Заключение

Мемристор (резистор с памятью) представляет собой перспективный элемент для аппаратной реализации синапсов. В данной работе рассмотрены вопросы

программирования мемристорных матриц (мемристорных кроссбаров). Получена оценка длительности импульса для задания требуемого значения сопротивления мемристора, исходя из начального значения этого сопротивления. Предложена аппаратная модель WTA-сети, реализующей ассоциативную память. Основой модели является кроссбар синапсов, базовым элементом которых являются мемристоры. Данная модель позволяет производить обучение сети в аппаратном режиме. Возможность настраивать сопротивление синапсов потребовала использования дополнительных элементов: каждый синапс снабжен КМОП-транзистором и к каждому ряду синапсов подведен источник напряжения, контролирующий напряжение на затворах КМОП-транзисторов. Эксперименты показали возможность достаточно точной настройки сопротивлений мемристоров импульсами напряжения и хорошее качество распознавания образов при их зашумлении, что подтверждает возможность использования данной модели в качестве устройства, реализующего ассоциативную память.

Список литературы

1. Chua L. Memristor – the missing circuit element // IEEE Transactions on Circuit Theory. – 1971. – vol.18. – pp.507-519.
2. Strukov D.B., Snider G.S., Stewart D.R., Williams R.S. The missing memristor found // Nature. – 2008. – vol.453. – pp.80-83.
3. Мемристор – шаг к искусственному интеллекту. новые разработки ученых ТюмГУ, 26.04.2012. – URL: <http://www.utmn.ru/n6468>
4. Pershin Y., Di Ventra M. Experimental demonstration of associative memory with memristive neural networks // Neural Networks. – 2010. – vol. 23, no. 7. – pp.881-886.
5. Chua L. Resistance switching memories are memristors // Applied Physics A: Materials Science & Processing. – 2011. – vol.102, no. 4. – pp. 765-783.
6. Ho Y., Huang G.M., Li P. Nonvolatile memristor memory: device characteristics and design applications // Int. Conf. on Computer-Aided Design (ICCAD). – 2009. – pp. 485-490.
7. Jo S.H., Chang T., Ebong I., Bhadviya B.B., Mazumder P., Lu W. Nanoscale memristor device as synapse in neuromorphic systems // Nanoletters. – 2010. – vol.10, no. 4. – pp. 1297-1301.
8. Kavehei O. Memristive devices and circuits for computing, memory, and neuromorphic applications. PhD thesis. The University of Adelaide, Australia, 2011. – 260 pp.
9. Lehtonen E. Memristive computing. University of Turku, Finland, 2012. – 169 pp.
10. Wu Q., Liu B., Chen Y., Li H., Chen Q., Qiu Q. Bio-Inspired Computing with Resistive Memories – Models, Architectures and Applications // Proc. of 2014 IEEE International Symposium on Circuits and Systems (ISCAS). – pp.834-837.
11. Володин В.Я. Компьютерное моделирование электронных схем. – СПб.: БХВ-Петербург, 2010. – 400 с.
12. Wagner P. The LTspice2Matlab function. URL: <http://www.mathworks.com/matlabcentral/fileexchange/23394-fast-import-of-compressed-binary-raw-files-created-with-ltspice-circuit-simulator>
13. Dorrán D. The runLTspice function URL: <https://dadorrán.wordpress.com/tag/run-ltspice-matlab/>
14. Biolek Z., Biolek D., Biolkova V. SPICE model of memristor with nonlinear dopant drift // Radioengineering, 18 (2). – pp. 210-214.
15. Falatic M. Memristor simulation with LTspice – a practical example! URL: <http://www.falatic.com/index.php/69>

АВТОМАТИЧЕСКАЯ ВЫРАБОТКА ПОВЕДЕНЧЕСКОГО КРИТЕРИЯ ПОИСКА ЦЕЛИ АНИМАТА

А. Г. Туманян¹, С. И. Барцев^{1,2}

¹Сибирский федеральный университет,
Россия 660041, Красноярск, Свободный 79

²Институт Биофизики СО РАН,
Россия 660036, Красноярск, Академгородок 50/50

Введение

Организмы, существуя в природе, руководствуются разного рода поведенческими навыками или паттернами для выживания: если организм голодает, значит нужно искать пищу, если рядом хищник, значит нужно убегать и др. Большинство паттернов – приобретенные в процессе жизни организма. Способность к формированию новых поведенческих паттернов помогает приспособиться к меняющейся среде, и позволяет выживать в новых условиях. Как устроены механизмы такого формирования, как они взаимодействуют друг с другом – являются важными и актуальными вопросами когнитивной биологии.

В настоящее время существует ряд биологически реалистичных методов обучения аниматов, т.е. роботов или их компьютерных моделей, предназначенных для изучения поведения живых организмов. Среди таких методов наибольшее распространение получили генетические алгоритмы [6], нейронные сети [1,2,4,5,9,10,16], спайковые нейронные сети [13] и обучение с подкреплением [11,12,15,17]. Генетические алгоритмы, обучение с подкреплением, спайковые сети хорошо показывают себя в ситуациях только с небольшими размерностями входных данных. Отрицательная черта супервизорных алгоритмов – необходимость многократного предъявления данных, чтобы все весовые коэффициенты успели стабилизироваться (если это вообще возможно для выбранной задачи).

В работе [14] была разработана модель импринта [3,7,8], благодаря которой анимат был способен в результате однократного предъявления образца ситуации запечатлеть последовательность действий, которые приводили к успеху. Модель анимата представляла собой зрительную систему с двумя одномерными сетчатками, на которые проецировались кисть руки и цель, а также рука-манипулятор, которая имела возможность изменять свое положение с помощью двух шарнирных соединений. В этой модели формирования импринта критерий достижения цели в анимата (уменьшение углового расстояния между кистью и целью на сетчатках) была заложена извне. Это было упрощение, позволяющее сконцентрироваться на главной задаче – проверке возможности формирования поведенческого паттерна при единственном предъявлении, характерном для импринта. После того, как это было показано, возник вопрос о том, как может формироваться организмом критерий, введенный в работе [14] извне. Ведь исходно организм не умеет сопоставлять положение световых пятен на сетчатке с положением объектов внешнего мира с которыми можно манипулировать и нет знания о том, что уменьшение углового расстояния двух световых пятен (первое световое пятно – кисть руки, второе – цель, например, еда) на сетчатке соответствует сближению объектов в реальности и, в конечном счете, захвату объекта.

В данной работе, главной целью ставится нахождение возможности существования алгоритма выработки ключевых соответствий между информацией от зрительной системы анимата и устройством модельной среды в которой «живет» анимат. Выработка поведенческого критерия поиска цели необходима анимату для осуществления возможности отличать "плохие" действия от "хороших", приводящих к цели.

Материалы и методы

Для разработки алгоритма поиска автоматического критерия использовался вычислительный стенд [14] в котором моделируется функционирование анимата, который имеет 2 искусственных глаза, на одномерные сетчатки которых происходит отображение цели и кисти руки, и сама рука-манипулятор (рисунок 1), которой анимат может управлять посредством двух шарнирных соединений.




Рис 1. Модель анимата

В режиме случайного поиска такого положения "руки" при котором "кисть" совмещена с объектом, при этом происходит потактовая запись положения "кисти" и объекта (входов) и команд поворота шарниров (выходов).

"Рука" движется по тактам, в каждый такт каждый из шарниров может повернуться на (-3, -2, -1, 0, 1, 2, 3) градуса. Углы поворота на этапе случайного поиска задаются генератором случайных чисел, а на этапе функционирования – обученной нейронной сетью.

Алгоритм случайного поиска прост:

- 1) начинается случайное движение рукой в произвольном направлении;
- 2) если в течении фиксированного времени рука достигла цели, значит сохраняем траекторию как успешную, если не достигла, значит не успешную.




Рис 2. Рабочая область с фрагментом траектории (слева), функционирование стенда (python 2.7), процесс поиска точек (справа)

Успешным попаданием в цель считалось состояние, когда рука попадет в доверительный радиус цели в течении определенного количества итераций N, условием не попадания являлось соответственно не способность анимата попасть в радиус цели за N шагов.

Алгоритм случайного поиска при успешном и не успешном результате работы формировал следующую таблицу данных: значение проекции кисти руки-манипулятора и значение проекции целевой точки на сетчатки глаз, а также угловые расстояния. Столбец state таблицы 1 использовался исключительно для сравнения результата работы алгоритма кластеризации и алгоритмом на прямую для кластеризации не использовался.

Таблица 1. Фрагмент базы траекторий (успешные/неуспешные). (L, R) – проекция координат руки на сетчатках, (tL, tR) – проекция координат цели на сетчатках, distL = угловая разность между проекциями руки и цели (L-левый глаз), distR = угловая разность между проекциями руки и цели (R-правый глаз), state - состояние траектории TRUE, значит, траектория приводит к цели, FALSE - нет.

№	L	R	tL	tR	distL	distR	state
1	0,6632	0,2162	0,6860	0,2460	0,022 8	0,029 8	true
2	0,6782	0,3695	0,6900	0,3620	0,019 3	0,007 5	true
3	0,5819	0,4380	0,5980	0,4400	0,018 1	0,002 0	true
4	0,6526	0,4546	0,6700	0,4580	0,020 8	0,003 4	true
5	0,7475	0,4103	0,7600	0,4060	0,016 8	0,004 3	true
6	0,7226	0,2848	0,7900	0,3380	0,120 6	0,053 2	false
7	0,8073	0,2060	0,6620	0,3720	0,311 3	0,166 0	false
8	0,5725	0,3138	0,5800	0,3260	0,019 7	0,012 2	true

На базе данных о траекториях (таблица 1) алгоритму необходимо «понять», чем отличаются траектории, которые достигли цель (True) от тех, которые не достигли (False). Человек, посмотрев на эти данные, сразу поймет, что дело в разности угловых расстояний между целью и рукой. Траектории, которые имеют малые расстояния distR и distL – достигают цели, траектории, которые имеют большое расстояние – не достигают. Алгоритму необходимо самостоятельно классифицировать эти траектории на 2 типа. В анимате мы использовали метод кластеризации Кохонена, который достаточно реалистичен с биологической точки зрения. В работе использовался программный пакет Tanagra 1.4 для обработки данных.

Результаты и обсуждения

В результате анализа данные были разделены на 2 кластера: C_1 – кластер, который содержал неуспешные траектории, и C_2 – кластер, который содержал успешные траектории (рисунок 2). Никакой внешний критерий не использовался, столбец State таблицы использовался только лишь с целью сравнить то, что выдал алгоритм с тем, как бы разделил траектории на группы человек.

В таблице 2 представлены результаты кластеризации, кластеры отличаются в первую очередь средними угловыми расстояниями distL и distR, при том, среднее квадратичное отклонение для параметров практически не отличается. Кластер C_1 содержал исключительно только неудачные траектории, соответственно кластер C_2 алгоритм определил, как «успешный» кластер. Из 330 траекторий 271 попали в кластер с успешными траекториями. В кластер №2 попали только неуспешные траектории, которые не привели к цели. Формально, это не было случайным поиском, нам необходимо было получить любым способом список траекторий, которые попадали в цель и не попадали, чтобы затем опираясь на эти данные анимат мог выработать критерий оптимальности движений руки.




Рисунок 2. Классификация траекторий по кластерам(зеленые точки – успешные траектории, красные - неуспешные)

Таблица 2. Результат кластеризации. Кластеры отличаются в первую очередь по средним значениям угловых расстояний, они выделены жирным.

Кластер №1 (20.8% элементов)			Кластер №2 (79.2% элементов)		
Параметр	Среднее значение	Среднеквадратичное отклонение	Параметр	Среднее значение	Среднеквадратичное отклонение
distL	0,28	0,08	distL	0,06	0,05
distR	0,13	0,05	distR	0,02	0,02

tR	0,39	0,10	tR	0,31	0,10
tL	0,71	0,09	tL	0,69	0,09
R	0,29	0,09	R	0,30	0,09
L	0,62	0,12	L	0,68	0,08

Процесс функционирования анимата предполагает следующие стадии:

- 1) Случайный поиск оптимальных (субоптимальных) действий, в результате которого после большого количества итераций случайным образом анимат все же достигает цели, получает подкрепление в виде сигнала «удовольствие».
- 2) Выработка поведенческого критерия предполагает генерализацию знания о захвате траектории, т.е. что именно происходило, когда анимат захватил цель, как повторить такое событие, именно этим руководствуется анимат. Данные получаемые случайным поиском добавляются в таблицу, которая непрерывно анализируется алгоритмом кластеризации и по истечении определенного времени, когда траекторий накопится достаточное количество, чтобы выделились кластеры - алгоритм передает управление в модель формирования импринта.
- 3) Модель формирования импринта собственно реализует быстрое обучение двигательной функции, оптимизирует движения по затратам энергии (чем короче траектория, тем эффективнее организм) и формирует полностью адекватный и реалистичной двигательный паттерн анимата в текущей среде. Этот паттерн будет актуален до тех пор, пока среда будет неизменна.

В результате функционирования модели было показано, что анимат, не используя заложенные критерии поиска, способен самостоятельно выявлять ключевые соответствия между информацией от зрительной системы анимата и устройством модельной среды в которой «живет» анимат.

Заключение

В статье показана возможность существования алгоритма выработки поведенческого критерия, который позволяет автоматически генерализовать знание о достижении цели, и связывать действия по достижению цели с входными данными сенсоров анимата. Этот алгоритм работает на начальном этапе формирования импринтов (запечатлений) поискового поведения, когда анимат ориентируясь на критерий совершает случайные и псевдослучайные действия, которые приводят его в конечном счете к цели. Существование алгоритма выработки ключевых соответствий между информацией от зрительной среды анимата и устройством модельной среды в которой он существует дает возможность создать единую не противоречивую модель анимата с автоматическим обучением и возможностью «переучиваться» в условиях меняющейся среды.

Список литературы

1. Барцев С. И., Гилев С. Е., Охонин В. А. Принцип двойственности в организации адаптивных сетей обработки информации, В кн.: // Динамика химических и биологических систем. — Новосибирск: Наука, - 1989 - С. 6-55
2. Балацкий Е.В. Вспомогательные импринты и поведение человека // Вестник Российской Академии Наук, - 2007. - том 77 - №10
3. Баранова А.А. Педиатрия: национальное руководство: в 2 т. — М.: ГЭОТАР-Медиа, 2009. — Т.1. — 1024 с.
4. Гаазе-Рапопорт М. Г., Поспелов Д. А. От амебы до робота: модели поведения. - М.: Наука. Гл. ред. Физ.-мат. Лит., 1987.-288 с.
5. Гаврилова Т. А., Хорошевский В. Ф. Базы знаний интеллектуальных систем. Учебник.— СПб.: Питер, 2000.
6. Гладков Л. А., Курейчик В. В., Курейчик В. М. Генетические алгоритмы: Учебное пособие. — 2-е изд. — М: Физматлит, 2006. — С. 320. — ISBN 5-9221-0510-8
7. Коршунов Ю.М., Коршунов Ю.М. Математические основы кибернетики.—М.: Энергоатомиздат, 1972.
8. Лоренц К. Кантонская доктрина априори в свете современной биологии // Журнал «Человек» -1997 -№ 5
9. Николлс Д., Мартин Р., Валлас Б., Фукс П., От нейрона к мозгу. Пер. П. М. Балабана, А. В. Галкина, Р. А. Гиниатуллина, Р.Н. Хазипова, Л.С. Хируга. - М.: Едиториал УРСС, 2003.- 672 с
10. Рассел С, Норвиг П., Искусственный интеллект: современный подход, 2-е изд.:Пер. с англ. - М.:Издательский дом «Вильямс», 2006 - 1408 с
11. Редько В.Г. Перспективы исследований на стыке информатики и биологии // Нейроинформатика, - 2007 - том 2 - № 1
12. Смит К.Ю.М. Биология сенсорных систем/ К.Ю.М. Смит; Пер. с англ. — М.: БИНОМ. Лаборатория знаний, 2005. — 583с
13. Синявский О.Ю., Кобрин А.И., Обучение с подкреплением спайковой нейронной сети в задаче управления агентом в дискретной виртуальной среде // Нелинейная динамика - 2011. -Т.7 - №4
14. Туманян А.Г., Барцев С.И. Простейшая поведенческая модель формирования импринта, Компьютерные исследования и моделирование, 2014, т. 6, № 5, с. 793-802
15. Carpenter, G.A. and Grossberg, S.. ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures // Neural Networks, - 1990 — 3 - 129-152.
16. Rumelhart D.E., Hinton G.E.,Williams R.J. Learning internal representation by error propagation // Paraller Distributed Processing. - 1986 - vol.1.- №8
17. Sutton R.S., Barto A.G. Reinforcement learning: An introduction. // Cambridge, MA: MIT Press — 1998 - 323 pp.

ИССЛЕДОВАНИЕ МЕТОДОВ ПОИСКА ОПТИМАЛЬНОГО ЗНАЧЕНИЯ ПАРАМЕТРА ФОРМЫ РАДИАЛЬНЫХ БАЗИСНЫХ ФУНКЦИЙ ПРИ РЕШЕНИИ ЗАДАЧ НЕЙРОСЕТЕВОЙ АППРОКСИМАЦИИ

Г.Ф.Убиенных

Пензенский государственный университет, *ugf@mail.ru*

Радиальные базисные функции (РБФ) широко используются для многомерной интерполяции и аппроксимации функций. Это обусловлено их хорошими аппроксимирующими свойствами, простотой реализации, легкостью адаптации к увеличению размерности решаемых задач. Было опубликовано большое количество статей и несколько монографий (в основном, зарубежных авторов), посвященных теории и применению РБФ для решения задач аппроксимации. Из наиболее значимых монографий можно отметить [1–3]. Решение задач многомерной аппроксимации на основе использования РБФ можно успешно осуществлять как на компьютерах традиционной архитектуры, так и на радиальных базисных нейронных сетях [4, 5].

Задача аппроксимации на основе РБФ может быть описана следующим образом. Заданы множество точек (узлов) $X = \{x_1, \dots, x_n\} \in R^d$ и множество скалярных значений функции в этих точках $\{f_i = f(x_i)\} \in R (i = 1, \dots, n)$. Найти (непрерывную) функцию $s(x)$ такую, что $s(x_i) = f(x_i), i = 1, \dots, n$.

РБФ – интерполянт задается выражением

$$s(x) = \sum_{j=1}^n \alpha_j \varphi(\|x - c_j\|, \varepsilon), \quad (1)$$

где $\|\bullet\|$ – евклидово расстояние между двумя точками, $\varphi(r)$ – РБФ, $r = (\|x - c_j\|)$ – радиус РБФ, c_j – центр РБФ, n – число узлов интерполяции, ε – параметр формы РБФ. Коэффициенты разложения $\alpha_j (j = 1, \dots, n)$ выбираются путем принуждения условий интерполяции $s(x_i) = f(x_i)$ на множестве узлов, которые обычно совпадают с центрами. Это приводит к решению системы линейных алгебраических уравнений (СЛАУ)

$$\begin{bmatrix} A \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{bmatrix} = \begin{bmatrix} f_1 \\ \vdots \\ f_n \end{bmatrix}, \quad (2)$$

где элементы интерполяционной матрицы A определяются как

$$a_{ij} = \varphi(\|c_i - c_j\|), \quad i, j = 1, \dots, n.$$

Для положительно определенных Φ эта матрица гарантированно является невырожденной [1]. Для вычисления интерполянта в m точках x_i на основе (1) формируется вычислительная матрица H размером $m \times n$ с элементами

$$h_{ij} = \Phi(\|c_i - c_j\|_2), \quad i = 1, \dots, m; \quad j = 1, \dots, n.$$

Вычисление интерполянта в m точках осуществляется путем матричного умножения

$$s(x) = H\alpha.$$

Наиболее широко используемыми на практике РБФ являются: $\Phi(r, \varepsilon) = \sqrt{1 + (\varepsilon r)^2}$ (мультиквадрик), $\Phi(r, \varepsilon) = 1/\sqrt{1 + (\varepsilon r)^2}$ (инверсный мультиквадрик), $\Phi(r) = r^2 \log r$ (сплайн-поверхность), $\Phi(r) = 1/(1 + r^2)$ (функция Коши), $\Phi(r, \varepsilon) = e^{-(\varepsilon r)^2}$ (гауссиан). Многие РБФ имеют параметр ε , называемый параметром формы. Меньшее значение параметра формы соответствует более «плоской» или «широкой» РБФ. Значение параметра формы оказывает сильное влияние на точность аппроксимации. На сегодняшний день нахождение оптимального значения параметра формы РБФ, при котором погрешность аппроксимации будет минимальной, является открытой проблемой. Цель настоящей работы – исследование одного из подходов к решению данной проблемы.

Суть подхода к нахождению “хорошего” значения параметра формы РБФ заключается в минимизации значения некоторой функции прогноза погрешности аппроксимации. В работе проводится исследование использования трех таких функций: кросс – валидации с исключением одного узла, обобщенной кросс – валидации и оценки максимального правдоподобия.

Кросс – валидация проверяет точность метода путем разделения имеющихся данных на две или более частей. Одна часть данных используется для построения аппроксимации, а другая часть – для оценки погрешности аппроксимации. Кросс – валидация с исключением одного узла (*LOOCV* – Leave One Cross Validation) использует $n-1$ точек данных для построения аппроксимации, а затем проверяет ошибку аппроксимации на оставшихся данных. Процедура повторяется, пропуская каждый раз одну точку, и для оценки относительной точности метода используется результирующее множество ошибок. Используя сумму квадратов ошибок для оценки погрешности аппроксимации по методу *LOOCV*, получаем

$$LOOCV(\varepsilon) = \sum_{i=1}^n \left| \tilde{f}_i(x_i) - f_i^2 \right|,$$

где $\tilde{f}_i$ – интерполянт, формируемый с исключением точки x_i .

Как известно, вычислительная сложность решения системы линейных алгебраических уравнений с плотной матрицей составляет $O(n^3)$. Вычисление *LOOCV* путем решения n СЛАУ потребует $O(n^4)$ операций, поэтому встраивание *LOOCV* в таком виде в алгоритм аппроксимации существенно увеличит его вычислительную сложность. Риппа (Rippra) показал [6], что

$$\tilde{f}_i(x_i) - f_i = \frac{\alpha_i}{A_{ii}^{-1}},$$

где α_i – i -ый коэффициент интерполянта $\tilde{f}$, полученный с использованием полного множества данных, A_{ii}^{-1} – i -ый диагональный элемент A^{-1} .

Вектор α может быть найден путем решения системы (2), а диагональный элемент матрицы A^{-1} может быть вычислен путем ее факторизации. В результате сложность вычисления $LOOCV$ на основе использования формулы Риппы будет составлять $O(n^3)$, а само вычисление будет производиться по формуле

$$LOOCV(\varepsilon) = \sum_{i=1}^n \left(\frac{\alpha_i}{A_{ii}^{-1}} \right)^2.$$

Обобщенная кросс-валидация (GCV – Generalized Cross Validation) представляет собой разновидность кросс-валидации с исключением одного узла, в которой диагональные элементы матрицы K^{-1} заменяются их средними значениями:

$$GCV(\varepsilon) = \frac{\sum_{i=1}^n \alpha_i^2}{\left(\frac{1}{n} \sum_{i=1}^n A_{ii}^{-1} \right)^2}.$$

Ее вычислительная сложность, как и для $LOOCV$, составляет $O(n^3)$.

Другой метод для предсказания, какое значение параметра формы будет минимизировать погрешность РБФ – интерполяции, заключается в использовании оценки максимального правдоподобия (MLE – Maximum Likelihood Estimator). В работе для ее нахождения для значения параметра формы РБФ ε , которое минимизирует ошибку интерполяции, использовалась функция

$$MLE(\varepsilon) = \log(f^T \alpha) + \frac{1}{n} \sum_{i=1}^n \log(\lambda_i(A)),$$

где $\lambda_i(A)$ – i -ое собственное значение A . Вычисления вектора коэффициентов α и собственных значений матрицы A требуют выполнения $O(n^3)$ операций, поэтому вычисление значения MLE для одного значения параметра формы ε имеет вычислительную сложность $O(n^3)$.

В работе в среде MATLAB проводились экспериментальные исследования по использованию $LOOCV$, GCV и MLE в качестве методов поиска оптимального значения параметра формы РБФ. Во всех экспериментах задача аппроксимации рассеянных данных решалась многократно путем РБФ – интерполяции. Для каждого интерполянта определялась среднеквадратическая погрешность по n^d равномерно распределенным точкам, где n – число узлов интерполяции, а d – размерность пространства аппроксимации. Результаты одного из экспериментов представлены на рис. 1: аппроксимировалась функция $f(x) = x_1 \cdot \sin^2(x_1) \cdot e^{-x_2^2}$ в области $[1, 2] \times [1, 2]$ при $n = 8$, в

качестве РБФ использовался гауссиан. В табл. 1 представлены результаты анализа графиков: значение параметра формы ε_{opt} , при котором достигается наименьшая погрешность аппроксимации, а также значение самой погрешности для каждого из методов. В этом эксперименте метод *MLE* определяет значение ε , самое близкое к тому, что минимизирует погрешность аппроксимации, однако, *LOOCV* и *GCV* определяют значения ε , приводящие к меньшим среднеквадратическим погрешностям, чем *MLE*.




Рис. 1. Графики зависимости погрешности аппроксимации тестовой функции от значения параметра формы РБФ (гауссиан) для различных методов оценки

Таблица 1
Результаты анализа графиков рис. 1

Метод	ε_{opt}	Среднеквадратическая погрешность
RMSE	$3.79 \cdot 10^{-1}$	$2.887 \cdot 10^{-7}$
LOOCV	1.23	$6.473 \cdot 10^{-6}$
GCV	1.23	$6.473 \cdot 10^{-6}$
MLE	$4.06 \cdot 10^{-1}$	$3.958 \cdot 10^{-7}$

На рис. 2 представлены результаты другого эксперимента, в котором аппроксимировалась та же функция, что и ранее, узлы интерполяции располагались в $n = 120$ случайно распределенных точках области того же размера, в качестве РБФ использовался инверсный мультиквадрик. В табл. 2 представлены результаты анализа графиков. В противоположность предыдущему случаю здесь наблюдается неустойчивость всех методов, кроме *MLE*, причем оптимальное значение ε лежит около границы области неустойчивости.

Результаты многочисленных экспериментов, проведенных в данной работе, показывают, что кросс – валидация с исключением одного узла, обобщенная кросс – валидация и метод, основанный на оценке максимального правдоподобия, являются приемлемыми методами для выбора параметра формы РБФ при решении задач многомерной аппроксимации.




Рис. 2. Графики зависимости погрешности аппроксимации тестовой функции от значения параметра формы РБФ (инверсный мультиквадрик) для различных методов оценки

Таблица 2
Результаты анализа графиков рис. 2

Метод	ε_{opt}	Среднеквадратическая погрешность
RMSE	$5.74 \cdot 10^{-1}$	$9.402 \cdot 10^{-3}$
LOOCV	$1.36 \cdot 10^{-2}$	$1.243 \cdot 10^{-2}$
GCV	$2.06 \cdot 10^{-2}$	$1.242 \cdot 10^{-2}$
MLE	$9.33 \cdot 10^{-1}$	$1.391 \cdot 10^{-2}$

Список литературы

1. Buhmann, M.D. Radial Basis Functions: Theory and Implementations / M.D. Buhmann. – Cambridge Monographs on Applied and Computational Mathematics, Cambridge University Press, Cambridge, 2003. – 264 p.
2. Wendland, H. Scattered Data Approximation / H. Wendland. – Cambridge Monographs on Applied and Computational Mathematics, Cambridge University Press, Cambridge, 2005. – 348 p.
3. Fasshauer, G.E. Meshfree Approximation Methods with MATLAB / G.E. Fasshauer – World Scientific Publishing Co. Pte. Ltd., 2007. – 520 p.
4. Убиенных, Г.Ф. Решение задач многомерной аппроксимации на основе использования радиально-базисных нейронных сетей / Г.Ф. Убиенных // Нейроинформатика, ее приложения и анализ данных: Материалы XVI Всероссийского семинара, 19 – 21 сентября 2008 г. / Под ред. А.Н. Горбаня, Е.М. Миркеса. – Красноярск: ИВМ СО РАН, 2008. – С. 149 – 152.
5. Убиенных, Г.Ф. Использование радиально-базисных нейронных сетей для решения задач интерполяции функций / Г.Ф. Убиенных // Вычислительные системы и технологии обработки информации: межвузовский сборник научных трудов – Вып. 8 (31). – Пенза: Информационно – издательский центр ПензГУ, 2008. – С. 18 – 21.
6. Rippa, S. An algorithm for selecting a good value for the parameter c in radial basis function interpolation / S. Rippa. – Advances in Computational Mathematics, 11, 1999, pp. 193 – 210.

ОРГАНИЗАЦИЯ ЕСТЕСТВЕННО-ЯЗЫКОВОГО ДИАЛОГОВОГО ВЗАИМОДЕЙСТВИЯ ЧЕЛОВЕКА С ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ ОБУЧАЮЩЕЙ СИСТЕМОЙ

В.А.Углев, Рогожникова М.А.

Сибирский федеральный университет, *uglev-v@yandex.ru*

Работа интеллектуальных автоматизированных обучающих систем (ИАОС) сопряжена с анализом большого массива информации о деятельности учащегося. Так как человек, как объект обучения, слабо формализуем, то для выявления значений его параметров и их учёта при принятии решений ядру ИАОС необходимо использовать комбинацию статистических и эвристических методов. Но не все параметры можно выявить автоматически, поэтому приходится организовывать диалог машины с учеником посредством специальной диалоговой подсистемы. Центральной проблемой в этой ситуации является выявление унифицированных схем (деревьев) ведения диалога при реализации электронного обучения, а также извлечение знаний из протоколов работы с диалоговой подсистемой, применимых для оптимизации и индивидуализации траектории обучения.

Диалоговые подсистемы в системах человеко-машинного взаимодействия делятся на такие, которые имеют «жестко» заданную структуру и содержание контента; генерируют контент по шаблону (вариативность фразы, но не структуры), а также реализуют свободный диалог (без заранее заданных структуры и содержания) [1]. Таким образом, организация диалогов по «жесткой схеме» малоперспективно при сопровождении произвольного учебного курса. С другой стороны, у современных обучающих систем недостаточно возможностей для эффективного анализа ответов человека при реализации полностью свободного диалога, что приводит к задаче поиска гибридной унифицированной схемы взаимодействия ученика с ИАОС, расширяющей возможности стандартного подхода применения шаблонов. При этом диалоговая подсистема должна быть ориентирована на тесное взаимодействие как с интеллектуальным ядром системы, так и с рядом моделей (модель учебного курса, модель ученика, модель учителя или предметного тьютора и пр.). Очевидно, что разработка унифицированного механизма работы диалоговой системы сов семи этими элементами требуется единый механизм концентрации и обобщения множества факторов. Далее рассмотрим и разовьём один из подходов, апробированный нами в учебном процессе на специальных дисциплинах информационного и математического профилей.

Выделим общую схему процесса обучения на базе электронных учебных курсов, охватывающих все этапы работы с системой: запись на курс (включая анкетирование и тест входного контроля), синтез индивидуализированного курса и выработка индивидуальной учебной программы, непосредственное обучение (работу с теоретическим и практическим материалом, промежуточные этапы контроля), а также итоговый контроль и завершение обучения. В ИАОС взаимодействие пользователя с системой предполагает итерационное обращение к электронному курсу и системе

контроля: логика переходов между модулями учебного курса определяется уровнем знаний ученика и решениями, принимаемыми системой [2]. В процессе работы с такой обучающей системой у ученика могут возникнуть затруднения и вопросы к составу, изложению и проверке теоретического и практического материала. Мы выделили четыре унифицированных направления ведения диалогов, которые покрывают всю укрупнённую схему процесса обучения (рис. 1.):

1. В самом начале обучения, когда система может, выяснив предпочтения ученика, составить для него индивидуальный учебный курс, учитывая уровень уже имеющихся знаний, цели обучения, причины изучения курса, время на обучение и другие параметры;
2. При решении конкретного задания из электронной тетради или виртуальной лаборатории ученику могут потребоваться дополнительные пояснения относительно терминологии или принципов решения задачи;
3. По результатам прохождения рубежного или контрольного тестирования у ученика может возникнуть целый ряд вопросов, например, по какой причине была выставлена та или иная отметка, каким образом недостаточные знания могут повлиять на дальнейшее обучение и какие могут быть действия ученика, чтобы повторить эффективность повторения пройденного материала;
4. Ученику могут потребоваться комплексные рекомендации о том, на что нужно обратить внимание и какой материал повторить для того, чтобы повысить эффективность обучения.




Рис. 1. Распределение диалогов для обобщённой схемы обучения в ИАОС

Каждый из них определяет унифицированную схему вопросов (дерево диалога), абстрагированную относительно предметной области обучения. Например, для диалога по направлению №1 такое дерево будет выглядеть так, как показано на рис. 2. Каждая оконная диалоговая форма³ сопровождается шаблоном композиции конвента, о чём далее будет написано подробнее.

³ Рассматривается базовая форма представления – в виде текстовых сообщений в соответствующем поле. Но это не обязательно должно быть отдельное интерфейсное окно: например, диалог может быть

Покажем общий подход к организации таких диалогов на базе ИАОС. Для этого рассмотрим требования к диалоговой подсистеме, специфику её интеграции с ядром обучающей системы, структурную и графическую схемы формализации диалога, а так же затронем вопросы стандартизации.

Требования к диалоговой подсистеме. Введём допущение, что диалоговая система должна быть нацелена на повышение качества взаимодействия ученика с ИАОС, а не только на организацию формальных переходов между интерфейсными формами системы. Тогда обозначим ряд технических требований, вытекающих из принципов организации такой подсистемы, согласно [3]:




Рис. 2. Укрупнённое дерева диалога по направлению №1

- Естественно-языковая форма ведения диалога (будем предполагать, что речь идёт о синтезе текстового диалога, не исключая дальнейшей доработки подсистемы до работы с аудиовизуальным диалогом);
- Комплексность регистрации и анализа доступных факторов об ученике и его работе с электронным курсом;
- Унифицированность схемы взаимодействия диалоговой подсистемы с интеллектуальным ядром ИАОС;
- Компактность хранения данных о структуре и содержании диалоговых окон;
- «Прозрачность» для пользователя логики принятия решений системой, за счёт дополнительных пояснений (реализация стратегии обратного вывода).

Указанные требования накладывают ряд ограничений на возможности интеллектуального ядра ИАОС, предполагая наличие генератора фраз и специального механизма обобщения факторов.

реализован в специальной панели (области) интерфейсной формы трансляции электронного курса или в виде агента (по аналогии с интерактивным помощником в MS Office).

Интеграция с интеллектуальным ядром обучающей системы. Архитектура подсистемы диалога не может быть реализована без тесной интеграции с логикой работы интеллектуального ядра (решателя) системы. Так как в требованиях указано, что нам потребуется комплексный анализ учебной ситуации для каждого ученика в ИАОС, то необходимо иметь механизм извлечения данных из протоколов работы системы, их обобщение и выработка решений. Эти решения, ограничиваясь потребностями исследуемой подсистемы, можно разделить на следующие группы:

- Выявление цели диалога (информирование/констатация, уточнение/детализация, объяснение логики работы, получение обратной связи), т.е. ответ на вопрос «зачем?»;
- Выявление формы ведения диалога, опираясь на специфику ситуации и психофизиологические особенности учащегося, т.е. ответ на вопрос «как?»;
- Определение содержания текущей диалоговой формы, опираясь на текущее дерево диалога и реакцию ученика, т.е. ответ на вопрос «что?».

Для ответа на эти вопросы ИАОС должна анализировать текущие показатели обучения, их динамику, а также учитывать цели модели ученика и модели учителя. Можно заметить, что это схема принятия решений фактически имитирует процесс афферентации [4], поэтому интеллектуальное ядро обучающей системы предполагает механизм эффективного обобщения. В качестве такого механизма можно предложить применение *когнитивных карт диагностики знаний (ККДЗ)*, опирающийся на четырёхуровневую стратегию обобщения при выработке решений [5]. Тогда *методика синтеза* контента конкретной диалоговой формы в виде совокупности фраз будет представлена следующей последовательностью этапов⁴:

1. Инициализация актуальной ветки дерева диалога, соответствующего направлению диалога;
2. Загрузка шаблона композиции контента текущей диалоговой формы;
3. Извлечение и обобщение данных из протоколов работы системы и ККДЗ для констатации обстоятельств текущей учебной ситуации;
4. Анализ и проверка гипотез по ККДЗ, определяющих решение системы и актуальные для вывода части контента;
5. Синтез фраз в естественно-языковой форме и их вывод на диалоговую форму в соответствии с унифицированным шаблоном;
6. Активизация дополнительных полей с релевантным контентом (справочным материалом, глоссарием и пр.);
7. Активизация актуальных элементов интерфейса, отвечающих за обработку дальнейших действий ученика (кнопки меню, гиперссылки, поля ввода и пр.), в соответствии с шаблоном;

Рассмотрим подробнее процесс формализации структуру диалоговой формы и организацию шаблона.

Структура текста диалога. Диалог машины с человеком, ориентированный на эффективный обмен информацией, предполагает формирование достаточно сложных и

⁴ Предполагается, что ККДЗ уже сформирована в памяти ИАОС.

содержательных высказываний. Это значит, что односложные вопросы/ответы машиной синтезироваться не должны, а все логические обобщения должны носить доказательный характер. Очевидно, что в подавляющем большинстве случаев и вопросы, и ответы системы будут составными [6]. При этом можно выделить ряд семантических блоков, определяющих синтез диалогового текста:

- Ядро (главная мысль) высказывания, содержащая формулировку вопроса или включающая ответ – это центральный элемент текста на диалоговой форме (например, «Уровень Ваших знаний оценен на отметку удовлетворительно!» или «Для перехода к следующему учебному модулю рекомендуется пройти тест. Начать тест?»);

- Пояснения текста, включенного в ядро высказывания, которое может включать:

- типовая для конкретной диалоговой формы аргументирующая фраза (например, «Оценка уровня развития компетентностей производится на основании комплексного анализа результатов работы с электронной тетрадью и специальных тестовых заданий.»);

- связанные заголовки и/или порядковые номера задач и тестовых заданий (например, «Вами были не верно решены задачи 1, 2 и 4.»);

- логические обобщения, сделанные на основе обращения к ККДЗ (например, «Вам рекомендуется повторно обратиться к учебному материалу из третьего модуля, имеющего высокую важность для учебного курса!»);

- общая цепочка рассуждений (например, «Для получения зачёта по данному учебному модулю требуется набрать не менее чем 51 балл, продемонстрировав низкое число угадываний⁵, а та же адекватное время работы с тестом!»);

- текущая цепочка рассуждений (например, «Система выставила Вам низкий балл за тест, в связи с тем, что Вы набрали 52 балла (это достаточно мало), при этом число угадываний при решении теста было высоко (78%), а время прохождения подозрительно мало (8 мин, что практически соответствует скорости решения экспертом)!»).

- Блок активных списков, позволяющих дополнить пояснения, которые не рационально представлять в виде сплошного текста:

- списки со ссылками на релевантные дидактические единицы и модули;

- связанные термины из глоссария;

- связанные формулировки компетентностей и умений;

- связанные заголовки задач и тестовых заданий;

- отдельные ответы ученика на тест и пр.

- Пояснения к перечню дополнительных действий (реакций), предусмотренных в диалоговой форме (например, «Выберите из списка дидактическую единицу, для которой необходимо получить расширенную рекомендацию:», «Согласны ли вы с объективностью оценки Вашего уровня знаний?», «Показать перечень неверно решенных заданий теста?»)

⁵ Предполагается, что каждый вопрос в банке тестовых заданий, не относящийся к специальным вопросам-предпочтениям, снабжен дистрактором «Затрудняюсь ответить», что способствует анализу попыток ученика «обмануть» систему.

- Блок активных полей, управляемых пользователем (например, поля ввода анкеты или список альтернатив на ответ из ядра высказывания);
- Элементы навигации по дереву диалога (кнопки, гиперссылки и пр.);
- Метаинформация, описывающая специфику вывода текста и логику его компоновки.

Со структурной точки зрения, диалоговый текст формируется из заранее определённой шаблоном последовательности следующих элементов:

- Строки-константы с текстом (S);
- Контекстно-изменяемые строки, вычисляемые по результатам согласования склонений или фазификации числовых показателей (C);
- Числовые переменные-вставки (цифры в арабском An и символьном Sn представлении, элементы списков I и массивов M);
- Тэги форматирования текста на форме (символы абзацев, переносов трок, выравнивания, отступов и пр.), включая гиперссылки, как механизм обеспечения быстрой навигации;
- Активные и пассивные визуальные компоненты V (изображения, поля ввода, списки, таблицы и пр.);
- Управляющие конструкции R , позволяющие проверять условия и делать выбор значений переменных и при обращении к электронному курсу или ККДЗ, а так же вызывать отдельные процедуры и функции ядра ИАОС.

Очевидно, что последовательность и наличие семантических блоков и структурных элементов могут быть произвольны: они ограничиваются целью диалоговой формы, спецификой её реализации и ситуационной важностью⁶ тех или иных блоков.

Шаблон описания текста диалога. Диалоговая подсистема ИАОС, опираясь на указанные выше четыре направления взаимодействия, должна иметь гибкий графический интерфейс. Так как различных этапов диалога, предъявляемых ученику в процессе активного обучения, должно быть не менее 150, то рационально использовать шаблоны, опираясь всего на 2-3 базовых варианта оконной формы.

Сформируем модель описания произвольного диалога в ИАОС, опираясь на элементы теории формальных языков [7]. Пусть имеются множества S , C , An , Sn , I , M , V и элементы R , формирующие терминальный словарь T , а так же набор вспомогательных символов N (знаки @, #, ~ и пр.). Так же будем полагать, что имеется стандартный начальный символ $H \in T$, а диалоговая подсистема обладает множеством правил вывода P . Тогда язык описания диалога можно представить в виде классической формальной грамматики:

$$L = (T, N, H, P).$$

Если мы имеем n диалоговых форм, обладающих вариативностью компоновки текста, то корректная с позиции синтаксиса и семантики языка L цепочка элементов, входящих в терминальный словарь для конкретного диалога D_i ($i \in [1..n]$), будет

⁶ Для получения обоснованной оценки уровня важности и рациональности включения тех или иных элементов диалоговую форму необходимо, чтобы в интеллектуальном ядре обучающей системы была реализована функция, имитирующая процесс рефлексии.

являться его шаблоном. Приведём пример фрагмента цепочки элементов D_{84} , определяющих содержание шаблона диалога, формируемого после вызова учеником функции пояснения причины выставления конкретной оценки после прохождения промежуточного контроля: ... [S#Вам была выставлена отметка «'; Sn# CurrMarc; S#'. Основанием для этого стал полученный в ходе контроля '; C#(Fz(An#CurrBall), 28); S#'балл.';] {S# ('; An# CurrBall; S#'% верных ответов из 100%.') } (>0) { S#Тестовые задания, которые были решены не верно:'. Здесь [] – обозначение границ обязательного ядра текста; {} – вариативные элементы с пороговым уровнем значимости для вывода; # – символ обозначения типизированной переменной; Fz() – функция фазификации значения аргумента в соответствии с конкретным нечётким множеством. Результаты отработки фрагмента диалога (2) представлен на рисунке рис. 3 (область дополнительно выделена рамкой).




Рис. 3. Пример интерпретации шаблона по (2) в оконной форме

Применение языка описания шаблонов предполагает вариативность содержимого диалога: наиболее значимые и информативные блоки включаются в текст, прочие не выводятся на форму. Уровень значимости определяется интеллектуальным ядром ИАОС, опираясь на специфику рассматриваемого диалога (базу знаний) и информацию из ККДЗ. Так как требуется обеспечить гибкость обучающей системы, то интерфейс формирования шаблонов представляется в виде мастера, а шаблоны хранятся во внешних файлах (интерпретируются системой на этапе вызова). Одним из вариантов реализации этого механизма и хранения кода шаблона может быть технология XML.

Отображение динамики работы с диалоговой подсистемой. Из рис. 2 видно, что дерево диалога можно представить в виде графа, узлами которого будут оконные формы, а рёбрами – реакция учащегося. Очевидно, что граф будет иметь петли, т.к. каждая ветка диалога предполагает возможность возвращения (повторного вызова)

шаблона или инициализацию внешних для диалоговой подсистемы механизмов ИАОС. Тогда оценку отдельных параметров познавательной деятельности учащегося можно будет по последовательности и интенсивности активизации соответствующих переходов по графу при возникновении определённой ситуации. В качестве примера на рис. 4 приведём схематизированные данные о переходах по графу при работе учащегося с первым диалогом (этап согласования состава индивидуального учебного плана для диалога из направления №1) в ходе проведения эксперимента. Опираясь на протоколы работы системы, из графа можно получить не только информацию о непосредственных предпочтениях ученика, но и оценить значения параметров, участвующих в проверке отдельных гипотез, выдвигаемых и проверяемых ИАОС для формирования модели ученика, индивидуальной модели курса и выработке решений. Например, для фрагмента графа с рис. 4 это следующий набор гипотез⁷:

- Насколько ученик ориентируется в специфике предметной области?
- Насколько ученик заинтересован в подстройке «под себя» курса?
- Насколько адекватны его действия?
- Насколько согласованы продекларированные им цели обучения и реакции?
- Насколько самостоятелен и самоуверен ученик?

При этом не исключено, что в процессе обучения у ученика изменятся жизненные цели и часть учебной программы придётся вновь корректировать (перекомпоновывать) в соответствии с изменившимися акцентами.



Рис. 4. Фрагмент графа переходов между узлами дерева диалога

⁷ В данной ситуации этапы анкетирования и входного контроля уже проведены.

Завершая рассмотрение вопроса организации естественно-языкового диалога взаимодействия ученика с ИАОС, следует отметить необходимость стандартизации как описания шаблонов диалоговых форм (формат хранения и интерпретации композиции контента), так и сценарии их вызова в соответствии со спецификой направления ведения диалога. Не смотря на то, что удалось выявить унифицированные направления ведения диалога, их эффективное применение в различных обучающих системах предполагает реализацию механизма обобщения с помощью когнитивных карт диагностики знаний. Как язык разметки шаблона, так и язык формирования сценария диалога должны включать конструктор (мастера формирования диалога), адаптированный для его применения учителем или предметным тьютором. Поэтому графический метод конструирования нам представляется наиболее оптимальным.

Список литературы

1. Организация взаимодействия человека с техническими средствами АСУ. В 7 кн. Кн. 2. Языковые средства диалога человека с ЭВМ. Практ. пособие /Ю.Н. Филиппович, Е.В. Родионов, Г.А. Черкасова; Под ред. В.Н. Четверикова. – М.: Высш. шк., 1990. – 159 с.
2. Рогожникова М.А. Унификация ведения диалога при автоматизации индивидуализированного обучения // Робототехника и искусственный интеллект: Материалы VI Всероссийской научно-технической конференции с международным участием. – Красноярск: Монография, 2014. – С. 195-199.
3. Uglev V.A., Rogozhnikova M.A. Individualized natural language dialogue with the students in the intellectual education system // Interactive Systems and Technologies: the Problem of Human-Computer Interaction. Volume VI – Collection of scientific papers. – Ulyanovsk: UISTU, 2015 (в печати).
4. Uglev V., Filimonov V.A., Mishkina N.Yu. Hybrid approach to the management by feedback when working with automated educational systems // International Siberian Conference on Control and Communications (SIBCON). – Omsk, 2015. – pp. 143-146.
5. Uglev V. Implementation of Decision-making Methods in Intelligent Automated Educational System Focused on Complete Individualization in Learning // AASRI Procedia, vol. 6, 2014. – pp. 66-72. DOI 10.1016/j.aasri.2014.05.010.
6. Белнап Н. Д., Стил Т.Б. Логика вопросов и ответов. – М.: Прогресс, 1981. – 288 с.
7. Ахо А., Ульман Дж. Теория синтаксического анализа, перевода и компиляции. Том 1. Синтаксический анализ. – М.: Мир, 1978. – 612 с.

ИНТЕЛЛЕКТУАЛЬНЫЙ РЕФЛЕКСИВНЫЙ АГЕНТ В СТРУКТУРЕ АВТОМАТИЗИРОВАННЫХ ОБУЧАЮЩИХ СИСТЕМ

В.А.Углев

Сибирский федеральный университет, *uglev-v@yandex.ru*

Процесс передачи знаний от машины к человеку, ориентированный на максимизацию эффекта от педагогического воздействия, сопряжен с комплексом технических и методологических сложностей. Очевидно, что, обладая информацией/знаниями в явном виде, разработчики современных обучающих систем будут отдавать предпочтение тем методам искусственного интеллекта, которые относятся к нисходящему подходу [1]. Реализация адаптивных индивидуализированных функций по выработке учебной программы, трансляции дидактического материала, осуществления тренировки практических навыков и контроля знаний/компетентностей предполагает формирование системой следующих моделей: модель учебного курса, модель ученика [2], модель обучения (фактически, это модель учителя), а также модель учебной ситуации. Таким образом, качество работы интеллектуальной автоматизированной обучающей системы (ИАОС) зависит как от качества формирования этих моделей, так и наличия механизмов их совместного использования для выработки решений по управлению индивидуальной образовательной траекторией [3]. Это обстоятельство предполагает наличие в интеллектуальном ядре ИАОС (решателе или планировщике) механизма критической оценки самого процесса взаимодействия между учеником и компьютером. Попробуем сформулировать сущность и контуры возможностей данного механизма, опираясь на элементы теории рефлексивного управления В.А. Лефевра.

Моделирование поведения субъекта и принятия им решений в теории В.А. Лефевра описывается с помощью математики. Для описания взаимодействия нескольких участников в сложной ситуации, он прибегает к некоторому дополнению теории графов, переходя далее к полиномам, отражающим функцию выбора предпочтительных действий каждого участника. Рефлексивное управление, согласно [4], предполагает выработку такого воздействия на объект управления, чтобы он принял решение, заранее подготовленное управляющей стороной. В.А. Лефевр выделил четыре вида управления: непосредственное воздействие на объект управления (традиционное управление), манипулирование путём изменения отношений, манипулирование порядком значимости и воздействие на неосознанную сферу (подсознание) объекта управления. Объединяя всё это в рамках единого математического подхода, автор теории рефлексивного управления отмечает, что появляется возможность моделировать процессы принятия решений относительно всех участников ситуации, предполагающей конфликт интересов.

Процесс обучения, как объект рефлексии в теории самого В.А. Лефевра напрямую не рассматривается (вплоть до сегодняшнего дня). Несмотря на это, как в задачах классической педагогики [5], так и в задачах комплексной информатизации процессов обучения [6] идея рефлексии со временем нашла своё место. Первая и недостаточно удачная попытка сделать обобщение идей рефлексии для автоматизированных

обучающих систем была предпринята в работе [7]. Но дальнейшего полноценного исследования не последовало. Поэтому мы повторно обратимся к этой теме, опираясь как на последние работы автора теории, так и на успехи в области инженерии знания и искусственного интеллекта.

Рефлексия в процессе непосредственного аудиторного/индивидуального обучения имеет место быть как со стороны ученика, так и со стороны учителя: оба оценивают свои возможности, оба имеют различные цели, оба вынуждены принимать решения. При этом между ними может формироваться как отношение взаимопонимания (союза), так и отношение противостояния (конфликта). При этом и учитель a , и ученик b должны иметь определённый образ себя (самосознание через самооценку) и образ собеседника (оценка). Если обозначить образ учителя через a^* , то при выработке решений он должен взаимодействовать с воспринятым (субъективным) образом ученика $b^{\sim}$, где очевидно, что $b \neq b^* \neq b^{\sim}$. В процессе взаимодействия учитель постоянно соотносит реального ученика со сформированным образом и корректирует его, попутно вырабатывая приемлемое педагогическое воздействие, направленное на повышение эффективности учебного процесса (рис., а). Здесь сплошная стрелка – это активное взаимодействие, а пунктирная – пассивное. На первой схеме видно, что учебный материал c , который частично или полностью должен быть освоен учеником, является инструментом в руках учителя и не имеет активной роли⁸.




Рис.1. Сущности, взаимодействующие в индивидуальном учебном процессе

Традиционное дистанционное или электронное обучение предполагает возрастание роли учебного материала и повышенную активность со стороны ученика, а вот предметный тьютор/учитель теперь вмешивается в учебный процесс реже. В этом случае схему взаимодействия сущностей можно представить в виде схемы с рис.1, б. Анализируя существующую практику по применению такого обучения при базовой подготовке специалистов [8], следует констатировать её низкую эффективность, обусловленную слабостью ключевой связи между сущностями a и b .

⁸ Кроме того, в современном аудиторном учебном процессе связь между b и c всё чаще становится пассивной (пунктир), т.к. навыки работы с текстами у студентов не достаточно развит.

При переходе к автономному обучению на базе ИАОС, ситуация принципиальным образом меняется. Теперь типовая ситуация автоматизированного обучения включает в себя следующие сущности: ученика b и комбинированный из a и c инструмент, т.е. обучающей системы, в которой размещён дидактический материал. Если ориентироваться на эффективное сопровождение учебного процесса, то тогда роль ИАОС состоит в том, чтобы полноценно заменить человека-учителя, имитируя модель его поведения для достижения наилучшего педагогического эффекта по отношению к отдельно взятому ученику или их группе [8]. Поэтому та часть инструмента, которая призвана по возможности обеспечить адекватное принятие решений, должна кроме прочего имитировать и функцию рефлексии. Далее, для обозначения такой подсистемы в составе ИАОС, будем использовать словосочетание *интеллектуальный рефлексивный агент* (ИРА).

Форма представления принимающей решение подсистемы ИАОС в виде интеллектуального агента была описана в работах [9-12]. При этом выделение функции рефлексии позволяет отнести ИРА к агентам, которые относятся по поредению к сильным [13], т.е. характеризуются «ментальными» свойствами. Взаимодействие со средой, в первую очередь с человеком-учеником через машинные интерфейсы, агент должен формировать его образ b^* , а атк же вырабатывать управляющее воздействие. Для повышения интеллектуальности агента, интерес представляют второй и третий тип управления по В. Лефевру.

Функционирование ИРА, исходя из специфики взаимодействия ученика с интерфейсами ИАОС при каждом сеансе работы, должно осуществляться в «фоновом» режиме. Следовательно, каждое действие ученика, фиксируемое обучающей системой, должно быть запотоколировано, проанализировано и принято решение о необходимости модификации базовых моделей и выработке ответных реакций [14]. Для условного представления процесса взаимодействия ученика с рефлексивным агентом, входящем в состав a , можно использовать схему на рис., в. Рассмотрим ряд базовых обобщённых рефлексивных актов, которые должны быть реализованы агентом в составе ИАОС, в процессе сопровождения учебного процесса:

- Оценка возможности эффективно обработать конкретный электронный курс и оценить результаты работы с ним (ответ на вопрос «достаточно ли моих возможностей и качества дидактического материала для обеспечения эффективного обучения?»);
- Оценка своей позиции по составу, глубине изучения и нормативам контроля относительно учебного курса, применительно к заявленной пользователем форме обучения (ответ на вопрос «сумею ли я полностью или частично удовлетворить заявленные потребности ученика?»);
- Оценка степени «разумной» адаптации состава конкретного электронного курса и его нормативов контроля под ученика (ответ на вопрос «где и насколько я буду готов уступить требованиям ученика в случае появления конфликта наших целей?»);
- Оценка адекватности и необходимости пересмотра выбранной стратегии

обучения (ответ на вопрос «эффективно ли я осуществляю педагогическое воздействие на ученика и как повысить его эффективность?»);

- Оценка достаточности имеющихся у ИРА объективных аргументов, для принятия решения или его объяснения ученику (ответ на вопрос «могу ли я убедительно принять эту гипотезу?»);

- Оценка значимости того или иного действия ученика для модификации какой-либо модели в ИАОС (ответ на вопрос «считать ли мне поступившую информацию о действиях пользователя значимой и какие параметры следует обновить?»);

- Оценка актуальности текущей оценки потребностей ученика (ответ на вопрос «должен ли я пересмотреть предположения о целях ученика (возможно, с уточнением через диалог), если имеется значительное расхождение ожидаемого поведения (по модели ученика) и фактического?»);

- Оценка корректности ведения диалога (ответ на вопрос «корректны ли были мои последние действия при текущей реакции ученика и как их компенсировать последствия или избежать в дальнейшем методологических ошибок по отношению к конкретному ученику?»);

- Оценка объективной готовности программно-технической и информационной компонент ИАОС, включая проверку корректности текущих пользовательских настроек обучающей системы (ответ на вопрос «готов ли я приступить к работе?»).

Сложность формирования образа себя a^* (подсистемы учителя/предметного тьютора) и образа ученика b^* предполагают наличие у ИРА механизма концентрации и комплексного анализа множества факторов учебной ситуации [9, 10]. Реализация этих механизмов можно осуществить через построение *когнитивной карты диагностики знаний* и четырёхэтапной стратегии принятия решений [11]. Тогда на первый план выходят следующие проблемные вопросы, затрагивающие архитектуру ИРА и всей ИАОС:

- Включать ли реализацию механизма синтеза когнитивной карты в состав экземпляра агента или иметь его в базовом ядре обучающей системы?

- Какие стратегии управления по В.А. Лефевру рационально включать в возможности агента⁹?

- На какой перечень событий в пользовательском интерфейсе должен реагировать агент?

- Достаточно ли иметь в ИАОС только агента-учителя и каковы будут его границы?

- Применять ли механизм миграции агента при активизации сеанса работы с

⁹ Здесь следует подчеркнуть, что теория рефлексивного взаимодействия в том виде, в котором она была предложена В.А. Лефевром в 1965 и доработана к сегодняшнему дню для анализа социальных процессов, не может быть адекватно применена к моделированию человеко-машинного взаимодействия. На наш взгляд, потребуется значительная адаптация и гибридизация с другими подходами.

сетевой ИАОС или всё выполнять на стороне сервера?

– Предусматривать ли в системе наличие механизма синхронизации агента и когнитивной карты для случаев, когда необходимо одну часть обучения осуществлять на автономной машине, а другую – при наличии связи с серверной частью?

При беглом ознакомлении с рассматриваемой темой может возникнуть вполне закономерный вопрос: почему была выбрана именно агентная реализация модели учителя? Не рассматривается же агент-ученик или агент-учебный курс. Ответ достаточно очевиден: инструмент сам должен адаптироваться к потребностям ученика, причём при работе в многопользовательском режиме процесс «сопровождения» каждого пользователя должен быть индивидуален (следует отметить, что когнитивная карта диагностики знаний так же строиться индивидуально)¹⁰. Тогда мы можем говорить даже о мультиагентной системе [11, 12], потенциально адаптируемой для индивидуальной или совместной работы с группой учеников [14].

В данной работе была осуществлена лишь обобщённая постановка задачи исследования и разработки модели интеллектуального рефлексивного агента в составе обучающей системы. Очевидно, что логика работы агента не может опираться исключительно на один подход, т.е. для описания функции рефлексии, на наш взгляд, будет недостаточно только теории В.А. Лефевра. Потребуется разработка междисциплинарной модели, сочетающей наработки в когнитивной психологии, нейрофизиологии, педагогики и инженерии знаний. Выше уже была отмечена перспективность интеграции агента с моделью когнитивных карт диагностики знаний. Это предполагает, что в ядре интеллектуальной обучающей системы необходимо реализовать процесс принятия решений, т.е. имитировать процесс афферентации [15]. Не исключено, что при более глубокой проработке вопроса будет выяснено, что эффективная имитация механизма рефлексии будет достигнута в сочетании с методами, относящимися к восходящему подходу в искусственном интеллекте.

Список литературы

1. Copeland J., Proudfoot D. Artificial Intelligence: History, Foundations, and Philosophical Issues // *Philosophy of Psychology and Cognitive Science*, 2006 - pp. 429-482
2. Карпенко А.П., Добряков А.А. Модельное обеспечение автоматизированных обучающих систем. Обзор // *Наука и образование*. – 2011. – №7. Режим доступа: <http://technomag.bmstu.ru/doc/193116.html>.
3. Углев В.А. О специфике индивидуализации обучения в автоматизированных обучающих системах // *Философия образования*. – 2010. – №2. – С. 68-74. Режим доступа: www.phil-ed.ru/Text/NumberJourn.html.
4. В.А. Лефевр. Лекции по теории рефлексивных игр. М.: Когито-Центр, 2009. –

¹⁰ Что касается учебного курса, то он создаётся единый для множества потенциальных учеников и лишь параметрически адаптируется к потребностям конкретного ученика. Сам же ученик в виде агента не требуется, т.к. он сам участвует в процессе обучения. Кроме того, образ ученика в ИРА формируется для работы агента-учителя и, следовательно, самостоятельного интереса в данной постановке задачи не представляет.

218 с.

5. Lipman M. Thinking in Education, 2nd Edition, Cambridge, 2003. – P. 304.
6. Машбиц Е.И. Психолого-педагогические проблемы компьютеризации обучения. – М.: Педагогика, 1988. – 192 с.
7. Артющина Л.А., Монахов М.Ю., Спирина Т.В., Троицкая Е.А. Рефлексия как необходимый компонент автоматизированной обучающей системы: постановка проблемы // Алгоритмы, методы и системы обработки данных: Сборник научных статей, Выпуск 14, 2009. – С.12-19.
8. Углев, В.А. Автоматизированные обучающие системы и компьютерное тестирование: системный кризис и перспективы развития // Модернизация российского образования: тренды и перспективы. Ч. 2. – Краснодар: АНО "Центр социально-политических исследований "Премьер", 2011. – С. 3-18.
9. Углев В.А. Выявление закономерностей и их усиление при обработке протоколов работы автоматизированных обучающих систем с помощью синтеза когнитивных карт диагностики знаний // Проблемы управления в социальных системах, том 6, вып. 9, 2013. - С. 108-121.
10. Углев В.А. Выявление и согласование целевых установок виртуальных агентов в задаче анализа ситуации автоматизированного обучения // Нейроинформатика, ее приложения и анализ данных: XXI Всероссийский семинар. – Красноярск, 2013.– С. 150–154.
11. Uglev V. Implementation of Decision-making Methods in Intelligent Automated Educational System Focused on Complete Individualization in Learning. – AASRI Procedia, - 2014. – Vol. 6. – pp. 66-72. doi 10.1016/j.aasri.2014.05.010.
12. Углев В.А. Системный подход к формированию структуры и логики работы мультиагентной автоматизированной обучающей системы // Системный анализ и информационные технологии: Материалы V Международной конференции. Т.1. - Красноярск: ИВМ СО РАН, 2013. - С. 299-303.
13. Слабое и сильное определения интеллектуального агента. – Электронный ресурс: режим доступа – <http://www.aiportal.ru/articles/multiagent-systems/weak-and-strong-intelligent-agent.html>
14. Uglev V.A., Filimonov V.A., Mishkina N.Yu. Hybrid approach to the management by feedback when working with Automated Educational Systems // International Siberian Conference on Control and Communications (SIBCON). – Omsk: OmGTU, 2015. – p. 1-4.
15. Углев В.А. Применение принципов теории функциональных систем П.К. Анохина для симуляции процессов принятия решений (на примере обучения) // Робототехника и искусственный интеллект: Материалы VI Всероссийской научно-технической конференции с международным участием. - Красноярск: Монография, 2014. - С. 176-182.

БИБЛИОМЕТРИЧЕСКИЙ АНАЛИЗ ВЕРОЯТНОСТИ ПОДДЕРЖКИ ИНИЦИАТИВНЫХ НАУЧНЫХ ПРОЕКТОВ РОССИЙСКИМ ФОНДОМ ФУНДАМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ

Р.А. Чиженкова

Институт биофизики клетки РАН, *chizhenkova@mail.ru*

В настоящее время отношение общества к науке, можно сказать, приобрело политическое значение [5]. Особое место отводится фундаментальной науке [8-13], поскольку именно на ее успехах базируется вся прикладная наука, дающая непосредственный выход в практику. Поэтому в наиболее развитых странах в середине прошлого века возникла организация специальных фондов для поддержки фундаментальной науки [4, 6]. В 1992 г. в России также был создан соответствующий фонд - Российский Фонд Фундаментальных Исследований (РФФИ) для финансовой поддержки работы научных коллективов и отдельных ученых.

Основные характеристики работы Фонда на начальном этапе его деятельности представлены в ряде статей [1, 2]. Материалы относительно 20-летнего юбилея РФФИ рассмотрены в специальном выпуске журнала "Вестник РФФИ" [3]. Тем не менее, до сих пор так не был проведен подробный анализ научных направлений, поддержанных Фондом, что послужило причиной появления наших библиометрических работ [12].

Основными видами конкурсов, проводимых РФФИ, являются конкурсы инициативных и издательских научных проектов. Разумеется, РФФИ производит отбор представляемых проектов для финансирования вследствие их разной значимости (по мнению экспертов фонда), а также собственной возможности. Настоящие исследования посвящены библиометрическому анализу именно вероятности поддержки РФФИ инициативных научных проектов в течение 20-летнего периода его деятельности (1993-2012 гг.).

Представленные здесь сведения основываются на данных, опубликованных в Информационных бюллетенях (ИБ) РФФИ, выходящих раз в год и освещающих итоги прошедшего конкурса.

Для каждого года составлялась обширная таблица с учетом суммарных данных, видов конкурсов, а также чисел поданных заявок и выделенных грантов. При этом вычислялась процентная вероятность поддержки проектов. Затем, во-первых, проводили объединение результатов по анализируемым рубрикам за весь временной период. Во-вторых, по всему полученному материалу изучали динамику величин по годам. В-третьих, вычисляли статистическую значимость различия величин, принадлежавших к разным рубрикам. Для статистического анализа использовали сравнение двух выборочных долей вариантов. Кроме того, был применен корреляционный анализ.

Общее число поддержанных проектов за 20-летний период деятельности РФФИ достигало большой величины - 74241. Основная масса грантов приходилась на инициативные научные проекты.

Число поддержанных инициативных проектов за указанный временной интервал деятельности РФФИ равнялось - 58667, что соответствовало 79.02% от общего числа. Однако числа поданных заявок по инициативным проектам в ИБ приведены без учета 1993-1995 и 2001 гг., т.е. в течение 16 лет, на которые приходилось 47234 гранта.

Количественные характеристики массивов выделенных грантов и поданных заявок продемонстрированы соответственно в табл. 1 и 2. Сведения о процентах поддержанных инициативных проектов представлены в табл. 3. Динамика чисел выделенных грантов по инициативным проектам нами в некоторой мере была уже описана [11], но данный материал здесь желателен для построения общей картины поддержки представляемых проектов.

Таблица 1

Динамика чисел поддержанных инициативных проектов в течение 20 лет

Годы	Число проектов	% от суммы за 20 лет	Сравнение со средним (U)
1993	2845	4.85	1.20
1994	2856	4.87	1.03
1995	2674	4.56	<u>3.60</u>
1996	4742	8.08	<u>21.24</u>
1997	2637	4.49	<u>3.94</u>
1998	2971	5.06	0.51
1999	3132	5.34	<u>2.60</u>
2000	2809	4.79	1.71
2001	3058	5.21	1.71
2002	3046	5.19	1.54
2003	2612	4.45	<u>4.28</u>
2004	2543	4.33	<u>5.48</u>
2005	2936	5.00	0.17
2006	3022	5.15	1.20
2007	2610	4.45	<u>4.45</u>
2008	2947	5.02	0.17
2009	2801	4.77	1.88
2010	2738	4.67	<u>2.74</u>
2011	2922	4.98	0.17
2012	2766	4.71	0.53
Сумма	58667	100.00	
Среднее	2933.35	5.00	

Примечания: достоверные различия при $p < 0,01$ подчеркнуты.

Как следует из табл. 1, числа поддержанных инициативных проектов колебались от 2543 в 2004 г. до 3132 в 1999 г., что представляло относительно небольшой диапазон - в 1.23 раза. Но на этом фоне, представляющем почти "плато", отмечался весьма существенный пик в 1996 г. - 4742, на который приходилось 8.08% от общего числа выделенных грантов за весь 20-летний период. По-видимому, последнее связано с общим увеличением профинансированных РФФИ проектов в данном году.

Следующим моментом библиометрического анализа являлось рассмотрение количественных показателей подаваемых заявок по инициативным проектам, к сожалению, не за 20-летний временной период, а лишь за 16-летний.

Число поданных заявок по инициативным проектам за 16 лет равнялось 150189. Динамика их годовых величин приведена в табл. 2.

Таблица 2

Динамика чисел поданных заявок по инициативным проектам в течение 20 лет

Годы	Число заявок	% от суммы за 20 лет	Сравнение со средним (<i>U</i>)
1993			
1994			
1995			
1996	15722	10.47	<u>42.20</u>
1997	11129	7.41	<u>12.61</u>
1998	9633	6.41	1.92
1999	9968	6.64	<u>4.66</u>
2000	8169	5.44	<u>9.32</u>
2001			
2002	9056	6.03	2.19
2003	8000	5.33	<u>10.69</u>
2004	7839	5.22	<u>12.06</u>
2005	8475	5.64	<u>6.85</u>
2006	9149	6.09	1.64
2007	7963	5.30	<u>10.96</u>
2008	8530	5.68	<u>6.84</u>
2009	8752	5.83	<u>4.66</u>
2010	9066	6.04	2.19
2011	9658	6.43	2.47
2012	9080	6.05	2.19
Сумма	150189	100	
Среднее	9386.81	6.25	

Примечания: как у табл. 1.

Табл. 2 показывает, что числа поданных заявок составляли от 7839 в 2004 г. до 9968 в 1999 г., т.е. колебались в диапазоне в 1.27 раз. Однако имел место выраженный пик числа поданных заявок в 1996 г. Он соответствовал 15722 заявкам, т.е. 10.47 % от их общего числа за 16-летний период.

Полученные сведения из ИБ по количественным аспектам выделенных грантов и предварительно поданных заявок по инициативным научным проектам позволили

оценить реальную возможность поддержки РФФИ последних. В течение рассматриваемого периода был поддержан 31.45% поданных заявок по инициативным проектам. Процентные числа поддержанных проектов претерпевали некоторые колебания по годам, что приведено в табл. 3.

Таблица 3

Динамика процентных чисел поддержанных инициативных научных проектов в течение 20 лет

Годы	Число заявок	Число грантов	% поддержанных	Сравнение со средним (<i>U</i>)
1993				
1994				
1995				
1996	15722	4742	30.16	<u>3.34</u>
1997	11129	2637	23.69	<u>17.71</u>
1998	9633	2971	30.84	1.24
1999	9968	3132	31.42	0.10
2000	8169	2809	34.39	<u>5.55</u>
2001				
2002	9056	3046	33.64	<u>4.34</u>
2003	8000	2612	32.65	2.18
2004	7839	2543	32.44	1.81
2005	8475	2936	34.64	<u>6.09</u>
2006	9149	3022	33.03	<u>3.16</u>
2007	7963	2610	32.78	2.43
2008	8530	2947	34.55	<u>5.93</u>
2009	8752	2801	32.00	1.09
2010	9066	2738	30.20	2.50
2011	9658	2922	30.25	2.48
2012	9080	2766	30.46	2.04
Сумма	150189	47234	31.45	
Среднее	9386.81	2952.13	31.45	

Примечания: как у табл. 1.

Из табл. 3 видно, что годовые колебания процентных чисел происходили от 23.69% в 1997 г. до 34.64 % в 2005 г. Их разность была 10.95%, что весьма велико, поскольку приближается к трети от общей величины (31.45%).

Дополнительно был проеден корреляционный анализ соотношения чисел подаваемых заявок и выделяемых грантов. При этом была выявлена их положительная

корреляционная взаимосвязь ($r = 0.89$; $p = 0.01$), что свидетельствует о значительной роли общего состояния внутренней возможности поддержки научных проектов РФФИ.

Таким образом, одним из первых нововведений молодой РФ явилось организация РФФИ по опыту других развитых государств. За два десятилетия деятельности РФФИ была оказана существенная поддержка проведению фундаментальной исследований. Для повышения возможности поддержки научных проектов весьма желательно увеличение финансового наполнения Фонда. В ближайшее время, по-видимому, имеется некая надежда на осуществление такого события. Данное предположения основывается на материалах выступления В.В. Путина на Общем собрании Российской академии наук в 2012 г., где он дал высокую оценку работе Фонда и сказал о намерении правительства увеличить его ресурсное наполнение в ближайшие годы [7].

Список литературы

1. Алфимов М.В. История создания Фонда // Вестник РФФИ 20 лет: Специальный выпуск. - 2012. - С. 10-15.
2. Алфимов М.В., Минин В.А., Либкинд А.Н. Страна наука - РФФИ // Вестник РФФИ. - 2000. - № 2(20). - С. 5-29.
3. Вестник РФФИ 20 лет: Специальный выпуск. - 2012.
4. Коннов В.И. Самоуправление на "передовой": становление национального научного фонда США // Вестник РФФИ. - 2007. - №4(54). - С. 10-15.
5. Лебедев С.А. Праксиология науки // Вопросы философии. - 2012. - №4. - С. 52-63.
6. Обама Б. Выступление в Национальной академии наук 27-ого апреля 2009 г. // В защиту науки. Бюл. № 6. Ред. Э.П. Кругляков. - М.: Наука, 2009. - С. 185-198.
7. Путин В.В. Выступление на Общем собрании Российской академии наук 22 мая 2012 // В защиту науки. Бюл. № 11. Ред. Э.П. Кругляков. - М.: Наука, 2012. - С. 7-14..
8. Чиженкова Р.А. Наука в современном мире // Актуальные проблемы социальной философии / ред. Э.В. Гирусов. - М., 1998. - С. 111-112.
9. Чиженкова Р.А. Библиометрический анализ нейрофизиологических аспектов действия неионизирующей радиации / Р.А. Чиженкова, А.А. Сафрошкина, Н.А. Слащева, В.Ю. Чернухин // Успехи современной биологии. - 2004. - Т. 124. - № 5. - С. 472-479.
10. Чиженкова Р.А. Динамика нейрофизиологических исследований действия неионизирующей радиации во второй половине XX-ого века. М.: Издат. дом Акад. Естествознания, 2012. - 88 с.
11. Чиженкова Р.А. Библиометрический анализ научных проектов по разным видам конкурсов, поддержанных Российским Фондом Фундаментальных Исследований // В: Моделирование неравновесных систем: Материалы XVII Всероссийского семинара / Ред. М.Г. Садовский. - Красноярск: Институт вычислительного моделирования СО РАН. - 2014. - С. 174-178.
12. Чиженкова Р.А. Российский фонд фундаментальных исследований. Библиометрический анализ поддержки научных проектов. Germany: Palmarium Academic Publishing, 2015. - 88 с.
13. Chizhenkova R.A. Bibliometrical review of neurophysiological investigation of action of non-ionized radiation in second half of the XXth century // Biophysics. - 2005. - Supplement. - № 1(50). - P. 163-172.

АНАЛИЗ НЕЙРОСЕТЕВОГО ИССЛЕДОВАНИЯ СЕКРЕТОРНЫХ И МОТОРНОЭВАКУАТОРНЫХ НАРУШЕНИЙ У ДЕТЕЙ С ЯЗВЕННОЙ БОЛЕЗНЬЮ ДВЕНАДЦАТИПЕРСТНОЙ КИШКИ В УСЛОВИЯХ СИБИРИ И КРАЙНЕГО СЕВЕРА

Т.В. Петровская, Л.А. Жуков, А.В. Хомич, Н.В. Решетникова

ГУ медицинских проблем Севера СО РАМН г. Красноярск,
Сибирский Государственный Технологический Университет,
Кафедра ИТ г. Красноярск
Краевое УПК, г. Красноярск, sibstu2006@rambler.ru

Нами впервые проведена исследовательская работа по использованию и внедрению в гастроэнтерологию разработанных новых нейросетевых методов для обработки показателей фракционного желудочного содержимого.

Впервые проведено сопоставление полученных результатов методов нейросетевой обработки показателей секрето-кислотопродуцирующей функции проявления синдрома ДГР, у детей при язвенной болезни двенадцатиперстной кишки (ЯБДПК) в условиях Сибири и Крайнего Севера.

В отечественной и зарубежной литературе материалов по данной теме нет.

Некоторые авторы не считают дуоденогастральный рефлюкс патологическим явлением, поскольку он наблюдается и у здоровых [10]. Ряд авторов отмечает, что при дуоденальных язвах рефлюкс также увеличен по сравнению со здоровыми, но не настолько выражено, как при язвах, локализующихся в желудке [9]. Другие исследователи даже усматривают компенсаторное увеличение рефлюкса для нейтрализации высокой кислотности желудочного сока [11]. Дуоденогастральный рефлюкс относят к группе агрессивных факторов [12].

Данная работа проведена Петровской Т.В. на базе клиники НИИ ГУ медицинских проблем Севера СО РАМН г. Красноярск, и экспедиционным методом в регионах Крайнего Севера (6 экспедиций) Заполярье, Таймыр, в гг. Норильск, Дудинка, пос. Хатанга, Сундари, Новорыбное и др., где исследование проводилось в условиях городских и поселковых поликлиник.

Алгоритмы обучения нейронных сетей, реализованные в нейроимитаторе, традиционно разделяют на две большие группы: с учителем (для задач с известным полем ответа); без учителя (задачи классификации или таксономии). В данной работе использовались обе группы алгоритмов.

Петровской Т.В. была создана база данных из 475 примеров исследованных детей (неинфицированных хеликобактерией) Сибири - г. Красноярск, Заполярье, Таймыра - г.Норильск и г. Дудинка, по 29 показателям фракционного желудочного зондирования (тощаковая, базальная, стимулированная гистамином и ферментативная пробы), с использованием MS Excel 7. Также учитывалась область проживания больного и выставленный диагноз. Используемые показатели приведены в Таблице 1.

Таблица 1

Структура файла базы данных входных параметров

Обозначение	Показатели X	Единицы измерения
V ₁	объем тощачовой порции	Мл
V ₂	общая HCl тощачовой порции	м*экв/г
V ₃	свободная HCl тощачовой порции	м*экв/г
V ₄ , V ₇ , V ₁₀ , V ₁₃	объем базальной секреции 1-4 порции	Мл
V ₅ , V ₈ , V ₁₁ , V ₁₄	общая HCl базальной секреции 1-4 порции	м*экв/г
V ₆ , V ₉ , V ₁₂ , V ₁₅	свободная HCl базальной секреции 1-4 порции	м*экв/г
V ₁₆ , V ₁₉ , V ₂₂ , V ₂₅	объем стимулированной секреции 1-4 порции	мл
V ₁₇ , V ₂₀ , V ₂₃ , V ₂₆	общая HCl стимул. секреции 1-4 порции	м*экв/г
V ₁₈ , V ₂₁ , V ₂₄ , V ₂₇	свободная HCl стимул. секреции 1-4 порции	м*экв/г
P ₁ 28	пепсин базальной секреции	мг %
P ₂ 29	пепсин стимулированной секреции	мг %
S 30	область проживания больного (+1 – Сибирь и Крайний Север, -1 – Красноярск и прилегающие районы)	
J 31	признаки наличия у больного язвы желудка и двенадцатиперстной кишки	
GD 32	признаки наличия у больного гастродуоденита	
DGR 33	признаки наличия у больного дуоденогастрального рефлюкса	

Цель работы:

Целью исследования явилось построение и анализ нейросетевых моделей (2,3,5,6,7,8), диагностики и прогноза показателей фракционного желудочного зондирования для изучения закономерностей секреторных нарушений, показателей у больных с язвенной болезнью двенадцатиперстной кишки, выявления зависимости от частоты интенсивности и степени выраженности дуоденогастрального рефлюкса (ДГР) на активность язвенного процесса.

Группы больных: в Заполярье «Таймыр» в Сибири

1. ЯБДПК
2. ЯБДПК

Методика исследования

Все значения показателей предварительно были приведены к диапазону [-1. +1]. Для каждой порции желудочной секреции автоматически конструировалась и обучалась нейронная сеть [2, 3, 6], предсказывающая значение общей и свободной HCl. Был проведен регрессионный и корреляционный анализ [8]. Результаты регрессионного и корреляционного анализа сравнивались с результатами нейросетевого анализа.

Используемые программные и аппаратные средства

Для синтеза нейросетевой модели использовался нейроимитатор BuilderBrains 1.0 под управлением ОС MS Windows NT. В качестве аппаратной платформы использовался кластер из трех персональных компьютеров с процессором Intel Celeron 1500 МГц и 256 Мб оперативной памяти.

Анализ результатов нейросетевого моделирования

Моделирование показало, наиболее успешно удалось спрогнозировать показатели V6, V9, V11, V12, V15, V17, V20, V21, V23, V24, V26, V27. Коэффициенты корреляции между прогнозируемым и фактическим значением показателей представлены в таблице 2.

Таблица 2

Коэффициенты корреляции между прогнозируемым и фактическим значением

Прогнозируе- мый показатель	V6	V9	V11	V12	V15	V17	V20	V21	V24	V26	V27
Нейросетевая модель	0.91	0.85	0.88	0.80	0.94	0.80	0.92	0.82	0.90	0.90	0.82
Линейная модель	0.86	0.85	0.94	0.87	0.84	0.78	0.54	0.52	0.80	0.80	0.80

Как видно из таблицы 2, только для показателей V11 и V12 линейная модель незначительно точнее нейросетевой модели. Для показателей V15, V20, V21, V24 и V26 нейросетевая модель значительно точнее линейной модели. Анализ влияния показателей на прогноз показал, что наибольшую значимость для подтверждения диагноза язвы имеет степень совпадения прогноза и фактического значения показателя **V26**. Для подтверждения диагноза дуоденогастрального рефлюкса наибольшую значимость имеет степень совпадения прогноза и фактического значения показателя **V6**.

Сравнение результатов нейросетевого и корреляционного анализа

Проведем сравнение оценок информативности показателей, полученных в ходе нейросетевого и корреляционного анализа. В качестве оценок информативности корреляционного анализа брались коэффициенты корреляции, взятые по модулю и

умноженные на 100. Ниже в таблицах приводятся оценки информативности нейросетевого и корреляционного анализа прогностических моделей для каждой группы больных детей.

Показано установление наибольшей диагностической значимости показателя V6 с помощью нейронной сети для подтверждения диагноза дуоденогастрального рефлюкса DGR и его влияние на клинико-эндоскопическую характеристику сочетанной патологии у детей.

Таблица 3

Оценки информативности показателей для проведения V6

	V3	V9	V15	GD	DGR
Нейросетевой анализ	8	24	4	11	30
Корреляционный анализ	76	75	60	5	1

Диаграмма 1. Оценка информативности показателей для прогнозирования V3, V5, V15, GD, DGR




Диаграмма показывает, что нейросетевой анализ существенно расходится с корреляционным анализом в оценке информативности V3, V9, V15 и DGR. Если в нейросетевом анализе информативность V9 заметно выше информативности V3 и V15, то в корреляционном анализе такое различие менее заметно. Вероятно, влияние V9 на прогноз имеет нелинейную составляющую. При нейросетевом анализе наибольшую информативность имеет факт наличия у больного DGR. При корреляционном анализе этот факт признается неинформативным. Это может быть объяснено тем, что влияние наличия у больного DGR на его показатель V6 носит существенно нелинейный характер.

1 пример. Группа больных с ЯБДПК, проживающих в Заполярье.

Таблица 4

Оценки информативности показателей для проведения V26

	V23	S	J	GD	DGR
Нейросетевой анализ	37	5	26	15	11
Корреляционный анализ	80	2	1	4	7




Диаграмма 2. Оценка информативности показателей для прогнозирования V26

Наибольшая информативность для прогноза V26 как в нейросетевом, так и в корреляционном анализе отдается показателю V23. Но остальные признаки корреляционный анализ определяет как неинформативные. Нейросетевой анализ оценивает признаки наличия у исследуемого J, GD и DGR как заметно влияющие на V26. Это связано с нелинейным характером влияния признака наличия J, GD и DGR на прогноз V26.


2 пример. Группа больных с ЯБДПК, проживающих в Сибири.

Таблица 5

Оценки информативности показателей для проведения V27

	V8	V9	V23	J	GD	DGR
Нейросетевой анализ	27	2	38	26	1	8
Корреляционный анализ	49	51	78	1	4	6

Диаграмма 3. Оценки информативности показателей при прогнозировании V27



ЯБДПК Сибирь

Признаки наличия у испытуемого J и DGR корреляционный анализ оценил как не влияющие на прогноз V27. Однако нейросетевой анализ учел нелинейность их влияния на прогноз и дал им заметную оценку информативности.

Сопоставление полученных результатов нейросетевой обработки показателей секреторной функции желудка из 2-х групп больных: 1-й с ЯБДПК (показатель V26) и вторая группа (показатель V27) подтверждает различие в нарушении секреции тяжести патологического процесса у больных с ЯБДПК, в зависимости от частоты регистрации и интенсивности дуоденогастрального рефлюкса достоверно увеличенной в условиях Заполярья.

Анализ нейросетевого результата исследований позволяет установить сущность агрессивного свойства ДГР.

Так, характерной особенностью является тот факт, что с эндоскопической регистрации ДГР при ЯБ ДПК происходит усиление интенсивности дуоденогастрального рефлюкса, который приводит к развитию выраженных гастритических заменений у детей, обследованных нами, обнаружены повышенная кислотообразования и субкомпенсация ощелачивания в антральном отделе желудка, повышение продукции соляной кислоты при базальной и стимулированной секреции секреторной активности как натошак, так и при стимуляции, непрерывное кислотообразование натошак, характерное для больных дуоденальными язвами, является результатом периодически повторяющихся дуоденогастральных рефлюксов.

Зависимость частоты и степени выраженности ДГР от активности язвенного процесса. В группе больных с зарубцевавшейся язвой и купированным воспалительным процессом частота регистрации ДГР достоверно ниже, чем при активной язве.

У больных язвенной болезнью двенадцатиперстной кишки интенсивность дуоденогастрального рефлюкса увеличена, начинает увеличиваться % сочетанной гастродуоденальной патологии. Количество нозологий возрастает от 3 до 5 в зависимости от региона проживания, пола, возраста, сезона года, наследственной отягощенности и многих отрицательных факторов, приводящих к хронизации процесса с частыми рецидивами, обострениями, осложнениями, эрозиями желудка, двенадцатиперстной кишки и с последующей трансформацией в язвенную болезнь.

Для иллюстрации приводятся выборочные примеры результатов клинко-эндоскопической характеристики сочетанной патологии при язвенной болезни двенадцатиперстной кишки у детей Заполярья.

1. Эзофагит, н/3 – 62,85%;
2. Гастрит антрального отдела – 62,85%;
3. Дуоденит – 14,3%;
4. Гастродуоденит – 102,85%;
5. ЯБЖ антрального отдела – 34,85%;
6. Множественные язвы антрального отдела желудка – 20,0%;
7. ЯБ луковицы ДПК – 28,6%;
8. Рубцующаяся ЯБ луков. – 42,85%;
9. Зарубцевавшаяся ЯБ луков. ДПК – 60,0%;
10. Эрозия луковицы ДПК – 28,6%;
11. Недостаточность кардии – 48,6%;

12. ДГР –84,85%;

13. Зияние привратника - 40,0%;

14. Гипертрофический гастрит – 101,05%,

В этой группе ДГР составил 84,85%. Нами установлено, что 85,3% случаев дуоденогастральный рефлюкс составляет у больных детей северян и 83,1% -80 % сибиряков с ЯБДПК, это указывает, что он способствует нарушению функционально-регуляторных механизмов гастродуоденальной системы, провоцируя повреждения слизистой оболочки желудка, приводящее в целом к выраженному нарушению желудочной секреции, проявлениям моторно-эвакуаторных расстройств, из которых наиболее типичный – дуоденогастральный рефлюкс, который свидетельствует об агрессивных свойствах своих на патологию у детей в экологических, экстремальных условиях Крайнего Севера, особенно Заполярья.

Выводы. Результаты данного нейросетевого исследования подтверждают несомненное преимущество нейронных сетей, как наиболее чувствительных диагностических и прогностических методов, указывающих на тяжесть течения и исход патологического процесса любой нозологии, важным подспорьем клинко-эндоскопического диагноза, позволяющего более эффективно, качественно и целенаправленно проводить патогенетическую комплексную терапию, реабилитационные и диспансерно-профилактические мероприятия для предотвращения рецидивов и обострений.

Разработанные и использованные нами новые методы нейросетевого моделирования могут быть использованы в педиатрической, терапевтической, гастроэнтерологической практике.

Список литературы

1. Горбань А.Н., Россиев Д.А. Нейронные сети на персональных компьютерах. Н.: Наука, 1996 г.
2. Гилев С.Е., Горбань П.Н., Миркес ЕМ., Коченов Д.А., Россиев Д.А. Определение значимости обучаемых параметров для принятия нейронной сетью решения об ответе // Нейроинформатика и нейрокомпьютеры: Тезисы докладов рабочего семинара, Красноярск, КГТУ, 1993 г., с.8.
3. Царегородцев В.Г. Производство полуэмпирических знаний из таблиц данных с помощью обучаемых искусственных нейронных сетей // Методы нейроинформатики. – Красноярск. Издательство КГТУ, 1998.
4. Россиев Д.А. Медицинская нейроинформатика // Нейроинформатика. Новосибирск: Наука, 1998 г. – 296с. С.137-211

5. Россиев Д.А. Самообучающиеся нейросетевые экспертные системы в медицине: теория, методология, инструментарий внедрение: Дисс.докт.мед.наук.- Красноярск, 1995 г. – 379 с.
6. Петровская Т.В., Орлова Е.П., Хомич А.В., Решетникова Н.В., Жуков Л.А. Нейросетевое изучение состояния секреторной функции желудка в детском возрасте с гастродуоденитами и язвенной болезнью в экологических условиях Сибири и Крайнего Севера // Красноярск. 2003 г. 23 с. Рукопись деп. в ВИНТИ 05,12,03 № 2113-B2003.
7. Петровская Т.В., Товбис Е.М. Нейросетевое исследование внутрижелудочной рН-метрии секреторной функции желудка у детей с гастродуоденитом, язвенной болезнью желудка, эрозивными гастритами в условиях Крайнего Севера и Сибири//Нейроинформатика, ее приложения и анализ данных: материалы XVI Всероссийского семинара. Красноярск; КГТУ, 2008, - с 102-106.
8. Гмурман В.Е. Теория вероятностей и математическая статистика. – 9-е изд.,стер. _М.: Высшая школа, 2003, 479 с.
9. Волосников Д.К. –Педиатрия, 1983, № 10, с.51-52.
10. Hinder R.,Fimmel C., Pace F.e.a//Z. Gastroent. – 1983.V.21.-P.21-26.
11. Саакян А.Г., Шварц В.Я., Щадига Л.В. Макарова Л.А.// Клин.мед.-1978.-№11.- с.42-47.
12. Денисов М.Ю. Болезни органов пищеварения у детей и подростков. – Ростов п/Д.: Феникс, 2005. -608 с.

СПИСОК АВТОРОВ

Ф.И.О.	Место работы	Стр.
Барцев Сергей Игоревич	Сибирский федеральный университет, ИФБиТ, Институт Биофизики СО РАН, <i>bartsev@yandex.ru</i>	115
Бахшиев А.В.	Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК)	3
Бир Алексей Александрович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, Алтайский государственный технический университет им. И. И. Ползунова, <i>yoykiee@gmail.com</i>	55
Благодарёв Алексей Юрьевич	69063, г. Запорожье, Запорожский национальный технический университет (ЗНТУ), <i>alexeus85@gmail.com</i>	9
Богатов Николай Маркович	350040, г. Краснодар, ФГБОУ ВПО «Кубанский государственный университет», т. 8(861)2199501*266, <i>bogatov@phys.kubsu.ru</i>	14
Головенкин Сергей Евгеньевич.	660022, г.Красноярск, ул.П.Железняк, 1, Красноярская Государственная медицинская академия, <i>gse2008@mail.ru</i>	19
Горбаченко Владимир Иванович	440026, Пенза, Красная ул., 40, Пензенский государственный университет, <i>gorvi@mail.ru</i>	97
Гунделах Ф.В.	Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК), <i>f.gundelakh@rtc.ru</i>	3
Гунер Михаил Викторович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, Алтайский государственный технический университет им. И. И. Ползунова, <i>horyzont1@mail.ru</i>	61
Жуков Леонид Александрович	Сибирский Государственный Технологический Университет, <i>sibstu2006@rambler.ru</i>	146
Иванова Марина Сергеевна	660041, г. Красноярск, просп. Свободный, д. 82, ст. Б Сибирский федеральный университет, институт архитектуры и дизайна, <i>ianimei@mail.ru</i>	70
Кайгородова М.С.	660074, г. Красноярск, ул. Киренского 26, корпус Г, Сибирский федеральный университет, Институт космических и информационных технологий, <i>kaigorodovam@gmail.com</i>	51
Кольчугина Елена Анатольевна	440026, Пенза, Красная ул., 40, Пензенский государственный университет, <i>kea_sci@list.ru</i>	27
Кувачева Наталья Владимировна	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>natalya.kuvacheva@gmail.com</i>	36

Курако Михаил Александрович	660074, г. Красноярск, Сибирский федеральный университет, Институт космических и информационных технологий, т. 8-923-285-67-12, <i>mkurako@gmail.com</i>	32
Масич Игорь Сергеевич	Сибирский Государственный аэрокосмический университет имени академика М. Ф. Решетнёва, Красноярск, просп. имени газеты Красноярский Рабочий, 31, <i>i-masich@yandex.ru</i>	19
Матюшин Геннадий Васильевич	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>medinfo@krasgmu.ru</i>	19
Моргун Андрей Васильевич	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>441682@mail.ru</i>	36
Овечкин О.Г.	Военный госпиталь в/ч 52630, г.Чита	19
Олейник Андрей Александрович	Украина, 69063, г.Запорожье, ул.Жуковского, 64, Запорожский национальный технический университет, <i>olejnikaa@gmail.com</i>	9
Осипов Михаил Игоревич	630090, Новосибирск, проспект Лаврентьева, 6, Институт систем информатики СО РАН, <i>inq1201@mail.ru</i>	109
Пелипецкая Елена Юрьевна	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>medinfo@krasgmu.ru</i>	19
Петровская Т.В.	660022, Россия, г. Красноярск, ул. Партизана Железняка, 3г, НИИ медицинских проблем Севера СО РАМН	146
Пожиленкова Елена Анатольевна	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>pozhiленkova@yandex.ru</i>	36
Покидышева Людмила Ивановна	660074, г. Красноярск, ул. Киренского 26, корпус Г, Сибирский федеральный университет, Институт космических и информационных технологий, <i>pok50gm@gmail.com</i>	51
Пятковский Олег Иванович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, Алтайский государственный технический университет им. И. И. Ползунова, <i>poi1952@mail.ru</i>	55, 61
Разумов Владимир Ильич	Омский государственный университет им. Ф.М. Достоевского, Россия, 644077, Омск, проспект Мира 55-а, <i>razumov@omsu.ru</i>	90
Решетникова Н.В.	Краевое УПК, г. Красноярск	146
Рогожникова Марина Анатольевна	662971, Красноярский край, г. Железногорск, ул. Кирова, д. 12А, Сибирский федеральный университет,	126

Росси́ев Дми́трий Анато́льевич	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>medinfo@krasgmu.ru</i>	19
Садовский Михаил Георгиевич	Институт вычислительного моделирования СО РАН, <i>msad@icm.krasn.ru</i>	36, 70
Салмина Алла Борисовна	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>allasalmina@mail.ru</i>	36
Самигулина Галина Ахметовна	050010, Республика Казахстан, г. Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий, <i>galinasamigulina@mail.ru</i>	86
Сизиков Виктор Петрович	Омский государственный университет путей сообщения, 644046, Россия, г. Омск, пр. Маркса, 35. Т./ф.: (3812) 31-42-19, <i>v_p_sizikov@mail.ru</i>	90
Симонов Константин Васильевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН, т. 89135954902, <i>simonovkv@icm.krasn</i>	32
Синицын Алексей Сергеевич	350040, г. Краснодар, ФГБОУ ВПО «Кубанский государственный университет», <i>Nj_1@inbox.ru</i>	14
Соломаха Анатолий Анато́льевич	440026, Пенза, Красная ул., 40, Пензенский государственный университет, <i>anatoly.solomakha@yandex.ru</i>	97
Субботин Сергей Александрович	Запорожский национальный технический университет, Украина, 69063, Запорожье, ул. Жуковского, 64, т.: +38- (097) 355-61-55, <i>subbotin@zntu.edu.ua</i>	9, 97
Тарков Михаил Сергеевич	630090, Россия, Новосибирск, пр. ак. Лаврентьева, 13 Институт физики полупроводников им. А.В. Ржанова СО РАН, <i>tarkov@isp.nsc.ru</i>	109
Туманян Артур Геворкиевич	Сибирский федеральный университет, ИФБиТ, <i>artur.tumanyan@gmail.com</i>	115
Убиенных Геннадий Федорович	440026, Пенза, Красная ул., 40, Пензенский государственный университет, <i>ugf@mail.ru</i>	121
Углев Виктор Александрович	662971, Красноярский край, г. Железногорск, ул. Кирова, д. 12А, Сибирский федеральный университет, <i>uglev-v@yandex.ru</i>	126, 135
Хилажева Елена Дмитриевна	660022, г. Красноярск, ул. Партизана Железняка, д. 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого, <i>elena.hilazheva@mail.ru</i>	36
Хомич А.В.	Сибирский Государственный Технологический Университет, <i>sibstu2006@rambler.ru</i>	146
Чиженкова Рогнеда Александровна	142290, Московская обл., Пущино, ул. Институтская, 3, Институт биофизики клетки РАН, <i>chizhenkova@mail.ru</i>	141

Шаяхметова Асем Серикбаевна	050010, Республика Казахстан, г. Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий, <i>asemshayakhmetova@mail.ru</i>	86
--------------------------------	---	----

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXIII Всероссийского семинара 25 – 27 сентября 2015 г.

Редактор М.Ю. Сенашова
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2014 г. Формат 60 × 90/8. (А4)
Бумага офсетная. Печать плоская.
Усл. печ. л. 13,0. Уч.-изд. л. 13,3.
Тираж 100 экз. Заказ 15

Отпечатано в типографии ИВМ СО РАН
660036, Красноярск, Академгородок