

Обучающаяся модель самоорганизующейся системы¹

В. Н. Шац, д. т. н.
Санкт-Петербург
vlnash@mail.ru

Теория информационной среды позволяет интерпретировать обучающую выборку как внешнюю информацию модели самоорганизующейся системы. Система функционирует как распределенный параллельный процессор, который обеспечивает ее адаптацию. Распознавание внешнего воздействия проходит стадии приема стимула, превращения в ощущение и затем в восприятие, представляющего собой классификацию информации на основе накопленного в системе опыта. Согласно этому подходу матрица данных отображается в ансамбль матриц восприятий. Эти матрицы зависят от параметров системы и имеют стохастический характер. Обучение завершается анализом частот комбинаций восприятий, присущих отдельным классам. Результатом работы системы является вероятностная оценка индекса класса. Приводятся результаты расчетов для двух задач.

Ключевые слова: самоорганизующаяся система, адаптация, ветвящаяся цепь, обучение, стохастическая модель.

1. Введение

В работе рассмотрено применение нового вида нейронных сетей, которые при анализе обучающей выборки моделируют процессы ощущения и восприятия в живой природе. В этом отношении работа продолжает исследования по персепtronу, служившего для автора этого термина Ф. Розенблatta моделью более общей познающей системы, которая включает в себя память и восприятие [1]. Он рассматривал персепtron как “родовое” наименование различных теоретических нервных сетей, которые состоят из множества элементов, связанных в единую сеть. В качестве элементов он использовал модели нейронов, которые непосредственно восходят к модели МакКаллока-Питтса. Здесь элементами являются “расчетные нейроны”, соответствующие новой концепции информационных взаимодействий в живой природе. Изучение этих взаимодействий отражает новый этап развития когнитивной науки [2–5].

Указанная концепция распространяется на биологические, социальные и технические системы, которые будем называть самоорганизующиеся системы. На ее основе разработана теория информа-

¹ © В. Н. Шац, 2012

ционной среды (ИС), предназначенная для моделирования процессов в указанных системах. Теория показала свою эффективность при моделировании процессов работы мозга, решении задач анализа данных и социальной психологии [6–10].

ИС образует множество элементов, которые получают информацию из окружающей среды и от других элементов, обрабатывают ее и передают смежным элементам. Теория базируется на постулате взаимодействия: элементы самоорганизующихся систем способны распознать в процессах физико-химической или другой природы, в которых они участвуют, информацию об уровне ее значимости для выполнения элементами своих функций. Этот уровень оценивает степень “опасности” или “полезности” информации в соответствии с латентной шкалой адаптационной природы, которая играет роль памяти.

Оценка может быть представлена вещественным числом, которое является измерителем информации. На это число и на содержащие его функции распространяются все правила действий над вещественными числами. Его нельзя сопоставить с величиной информации, измеренной по Хартли - Шеннону. ИС содержит множество систем из элементов, обладающих единым языком взаимодействия и шкалой, согласно которой оценивается полученная элементами информация.

Простейшей формой системы является цепь последовательно соединенных элементов, занимающих произвольное положение в пространстве. Следующая по сложности система состоит из первичной цепи элементов, каждый из которых является начальным элементом прикрепленной к нему цепи. Системы более сложной формы также организованы в виде ветвящихся цепей, состоящих из элементов предшествующего иерархического уровня.

2. Свойства самоорганизующейся системы

Взаимодействие цепей основано на предположении о неразрывности потока информации, согласно которому приращение Δu внутренней информации $u = u(x, t)$ состоит из суммы приращения Δh внешней информации $h(x, t)$ и взвешенной суммы приращений x и t :

$$\Delta u = (\Delta x/a + \Delta t/b)\varphi u + \Delta h,$$

где x — координата элемента, измеряемая вдоль цепи, t — время, a и b — параметры масштаба, φu — распределенный параметр, который зависит от свойств цепи, включая пороговые ограничения, а также свойств присоединенной цепи и ее внешней информации.

При переходе от приращения к дифференциальному из этого соотношения получим уравнение распространения информации:

$$a \frac{\partial u}{\partial x} + b \frac{\partial u}{\partial t} = \varphi u + g, \quad (g = a \frac{\partial h}{\partial x} + b \frac{\partial h}{\partial t}).$$

Решение этого линейного дифференциального уравнения в частных производных зависит от расчетного параметра $p = t - bx/a$. При $p < 0$ значение $u(x, t) = 0$, при $p = 0$ в элементе x в момент $t+0$ возникает информация $u > 0$. Соответствующий импульс поступает также в начальный элемент присоединенной цепи, для которой он играет роль внешней информации. Начальные условия для этой цепи имеют вид $\tilde{u}(0, 0) = u(x, t)$, где $\tilde{u}(\tilde{x}, \tilde{t})$ обозначает внутреннюю информацию цепи, а \tilde{x}, \tilde{t} — координаты ее элементов.

Очевидно, вторичная цепь для некоторой цепи является первичной для цепи более низкого уровня. Поэтому цепь любого уровня одновременно является элементом цепи более высокого уровня. Отсюда следует, что при использовании простейшей самоорганизующейся системы, как инструмента для решения определенной задачи, можно представить ее в виде цепи, элементами которой являются “расчетные нейроны”. Под ними следует понимать всю совокупность ветвящихся цепей нижерасположенных иерархических уровней при полученной ими внешней информации.

Все цепи системы по единой схеме и совместно обрабатывают полученную каждым элементом внешнюю информацию в соответствии с уравнением. Они выполняют функцию распределенного параллельного процессора, работа которого обеспечивает существование системы в условиях изменяющейся внешней среды. Поэтому, теория ИС дает количественное описание механизма адаптации самоорганизующейся системы, где “живой процессор” используется для когнитивного анализа афферентной информации. Его схема работы была реализована в вычислительной модели модуля нервной системы [10].

Укажем на общие моменты теории ИС и некоторых результатов исследований о работе мозга. В работе [12] отмечается “наличие индивидуальной шкалы определения ценности сообщения, воспринимаемого индивидом (как на системном, так и на элементарном

клеточном уровне организации)". В работах [4, 11, 12] показано, что субъект отображает внешнюю информацию, стимул, в ощущения. Связь ощущения и стимула устанавливает закон Вебера-Фехтнера. Ощущения используется мозгом для распознания класса явлений, к которому принадлежит стимул. Распознавание происходит путем сопоставления ощущений с эталонным образцом, хранящимся в памяти [12].

Этот анализ проявляет основные моменты адаптационного процесса: стимул превращается в ощущение, а ощущение — в восприятие. Оба процесса преобразования информации происходят по единой схеме распознавания путем классификации информации на основе некоторой шкалы. В соответствии с этой концепцией адаптации самоорганизующейся системы в работе предлагается адаптационный метод решения задачи обучения, который реализуется с помощью модели системы (далее "модель"). Она играет методологическую роль и одновременно является вычислительным инструментом.

Настоящая работа служит продолжением исследований по приложению теории ИС в части решения задач обучения. Здесь будет рассмотрен принципиально другой метод их решения, чем в работах [7, 9], где оно строилось путем "расширения" данных. Аналоги ощущения и восприятия самоорганизующейся системы, реализуемые моделью, также именуются как ощущение и восприятие.

3. Постановка задачи

Рассматривается бесконечное множество объектов q , которые характеризуются количественными признаками q_1, \dots, q_M и распределены по классам $\omega = \omega_1, \dots, \omega_{M_i}$ по неизвестному правилу. Из этого множества случайным образом получена обучающая выборка из M_s объектов, имеющая матрицу данных \mathbf{Q} . В задаче требуется классифицировать произвольный объект множества.

Решение задачи основано на применении модели, для которой обучающая выборка играет роль афферентной информации. Модель используется в двух режимах. Первоначально она применяется как некоторый инструмент для решения обратной задачи: по известной классификации информации требуется найти неизвестные шкалы для модели с определенными свойствами. В результате модель "обретет" память, что позволит ей распознавать новую ин-

формацию. Таким образом, вначале модель используется в режиме обучения, а затем в режиме распознавания, естественном режиме работы самоорганизующейся системы.

Рассмотрим схему обработки информации в модели. Ее воспринимают и оценивают элементы модели. Упорядоченный набор информации, составляющей стимул, оценивают все элементы модели, образующие цепь. Элементы цепей "специализируются" на восприятии определенного компонента стимула и получают определенные ощущения от его воздействия. Совокупность таких ощущений будет воспринята моделью как объект определенного класса. Все перечисленные оценки производятся согласно неизвестным шкалам.

Из изложенных соображений следует содержание первого этапа решения задачи, который можно условно назвать "переход от данных к ощущениям". Здесь модель должна преобразовать вектор $q = (q_1, \dots, q_M)^T$ в вектор $d = (d_1, \dots, d_M)^T$. Компоненты d_1, \dots, d_M соответствуют ощущениям элементов системы и представляют собой дискретные величины, которые можно рассматривать как символы некоторого алфавита \mathfrak{X} . Поэтому вектор d является строкой символов. Переход от вектора q к строке символов d влечет за собой дальнейшие изменения в схеме решения задачи обучения.

Существующие схемы решения таких задач исходят из предположения о том, что мерой близости двух объектов является аналитическая функция координат соответствующих векторов (например, расстояние между ними). Оно позволяет определить поверхности, которые разделяют объекты на классы. В отношении векторов с символыми компонентами это предположение не выполняется, поскольку не существует измерителя близости ощущений. Задача принимает форму многих задач молекулярной биологии, где изучение биологических феноменов сводится к анализу строк.

Будем исходить из следующих соображений. Очевидно, что, даже при одинаковых областях изменения признаков, объекты каждого класса отличаются от остальных объектов присущими только им свойствами. Согласно условию задачи есть некоторое неизвестное правило разделения бесконечного множества на классы. Это означает, что существует неизвестная условная плотность вероятности $\mathbf{P}(\omega_i | q)$ класса ω_i для объекта q [13]. Поскольку

$$\mathbf{P}(\omega_i | q) = \mathbf{P}(\omega_i | q_1, \dots, q_M),$$

то из этого предположения следует, что между признаками таких объектов установлены определенные соотношения, носящие вероятностный характер. Поэтому промежуточной целью является поиск приближенных зависимостей для указанных плотностей.

4. Дискретизация призраков

Очевидно, что для самоорганизующейся системы и для задачи обучения объект представляет собой “черный ящик”, который характеризуется некоторыми признаками. Однако система воспринимает его как нечто целое, а при решении задачи обучения происходит “дискретизация” объекта, поскольку он приближенно учитывается как набор независимых признаков определенной интенсивности. Кроме того, для системы и задачи эти признаки могут не совпадать. Введение символов означает снижение степени дискретизации и сближение обоих подходов. Он ведет к сжатию данных, поскольку символ заменяет значение признака в некотором диапазоне его значений.

Рассмотрим вопрос о величине параметра дискретизации Nr — количестве символов для отображения $q \rightarrow d$. По сути дела, это вопрос о градуировке шкалы признаков, или о необходимой точности наших знаний об объектах для понимания содержания конкретного “черного ящика”. С увеличением Nr повышается точность представления информации обучающей выборки. Вместе с тем сохраняется вопрос о том, насколько точно эмпирические данные отражают характеристики классов объектов. При достаточно большом значении Nr увеличение дисперсии помех в векторе q может привести к качественной ошибке в представлении вектора d .

Здесь целесообразно руководствоваться известными соображениями о том, что природа экономна и точность измерения характеристик воздействия среды, обеспечивающая принятие надлежащих решений, не должна быть избыточной. Очевидно, для постановки диагноза заболевания не следует измерять температуру тела с точностью до сотых долей градуса. Имеющиеся данные могут быть зашумлены и из-за излишней точности измерения параметров объектов.

Величина Nr определяет число различных объектов, которое может быть представлено вектором d . Общее число комбинаций признаков одного объекта, которые можно описать с помощью стро-

ки q_1, \dots, q_M , равно $M * Nr$. Из этих комбинаций требуется создать различные сочетания по M признакам. Количество различных объектов, которое можно описать с помощью рассматриваемой строки, равно

$$K = C_{M*Nr}^M = \frac{(M * Nr)!}{M!(M * (Nr - M))!}.$$

Значение K , равное 1 при $Nr = 1$, экспоненциально возрастает с увеличением Nr . Например, при $M = 13, Nr = 5$ значение $K = 1.6 * 10^{13}$. Цветовая палитра из 455 цветов, может быть передана стимулом, который имеет всего три компонента, соответствующих красному, желтому и синему простым цветам ($M = 3$), каждый из которых имеет только 5 уровней ($Nr = 5$). Из этого анализа следует, что данные реальных выборок можно описать, ограничиваясь значением $Nr < 10$.

5. Вычисление вспомогательного отображения

Системы ИС позволяют найти непрерывное почти всюду нелинейное отображение вектора $q = (q_1, \dots, q_M)$ на некоторый вектор $c = (c_1, \dots, c_M)$. Будем вычислять отображение $q \rightarrow d$ согласно схеме $q \rightarrow c \rightarrow d$, где c — некоторый вспомогательный вектор. Эти вычисления способны выполнить большое количество моделей, отличающихся своей архитектурой и параметрами. Выберем из них вариант, который является простейшей моделью цепи нейронов [6, 7].

Здесь расчетным нейроном (РН) служит элемент первичной первичной цепи, к которому присоединена вторичная цепь элементов. Количество РН в цепи равно M , в k -ом РН входящая информация равна q_k . Далее будем использовать простейший вариант [9] такого отображения $q \rightarrow c$, который дает функция $F(q, \alpha) = c$, зависящая от параметра $\alpha = (\alpha_1, \dots, \alpha_M)$. Она определяет следующие соотношения между компонентами векторов q и c : ($1 \leq k < M$)

$$c_1 = \alpha_1, c_{k+1} = c_k \left(1 - \frac{1 + (\alpha_k + \alpha_{k+1})q_{k+1}\Delta x/2 - q_{k+1}/q_k}{1 + (\alpha_k/6 + \alpha_{k+1}/3)q_{k+1}\Delta x} \right). \quad (1)$$

Значение α должно удовлетворять ограничениям: $0 < \alpha_1 \ll 1, \alpha_p > 0, p \in (2, M)$. Применяя эти формулы для всех объектов обучающей выборки, вычислим матрицу \mathbf{C} .

Рассмотрим некоторые вопросы применения матриц **Q** и **C** для решения задачи.

Обозначим через $P(\omega_i | q; \alpha)$ приближение плотности $\mathbf{P}(\omega_i | q)$ при данном α . Из (1) следует, что $c \rightarrow q$ при $\alpha = 0$. Поэтому плотность $P(\omega_i | q; 0)$ вычисляется с помощью матрицы данных **Q**. Параметр α играет роль возмущения. Он позволяет построить непрерывное почти всюду “продолжение” обучающей выборки в некоторой ее окрестности и вычислить соответствующую матрицу **C**.

Формулы (1) отображают вектор q в древесной системе координат c_1, \dots, c_M , так как компоненты c_k находятся из рекуррентных зависимостей. Значения c_k оказываются взаимосвязанными, и независимые величины q_k трансформируются в зависимые c_k . Это изменение облегчает поиск функциональной связи между объектами определенного класса. Очевидно, матрицы **Q** и **C** дают информацию об исследуемых объектах со случайными помехами по отношению к неизвестной “истинной” информации. Можно считать, матрица **C** дополняет информацию, содержащуюся в обучающей выборке.

Поскольку α является случайной величиной, то рассматриваемый метод обучения относится к числу стохастических методов. Он отражает случайность процесса восприятия в самоорганизующейся системе, в котором могут участвовать несколько параллельных систем, формирующих ощущения. Будем вычислять матрицу **C** при различных α . Тогда получим ансамбль матриц, которые дополнят наши знания об объектах, содержащиеся в матрице **Q**.

6. Расчетные зависимости

Вычислим отображение $c \rightarrow d$ путем представления компонентов вектора c в определенных шкалах. Для каждого признака будем использовать простейшие метрические шкалы с одинаковыми интервалами и одинаковым их числом Nr . Указанное отображение найдем путем квантования по каждому признаку, которое сводится к следующей процедуре.

Из матрицы **Q** найдем минимальное $c_{k,mi}$ и максимальное $c_{k,ma}$ значение c_k . Соответствующий отрезок $(c_{k,mi}, c_{k,ma})$ разбиваем на Nr интервалов. На r -ом интервале $c_{kr} \leq c_k < c_{k,r+1}$ получим для объекта q значение $d_k = \mathfrak{R}_r$, соответствующее r -ому символу некоторого алфавита \mathfrak{R} , $r \in (1, Nr)$. Тогда в новых координатах рас-

сматриваемый объект будет приближенно описываться в виде строки символов (d_1, \dots, d_M) , где индекс r зависит от номера объекта в матрице данных \mathbf{Q} . Таким путем определим матрицу символов \mathbf{D} .

Поскольку d_k представляет значение c_k в алфавите \mathfrak{R} , то вектор d с определенной погрешностью также учитывает взаимосвязи q_k и при данном α реализует взаимно однозначное соответствие отображения $q \rightarrow d$. Поэтому “ощущения” d_k оказываются взаимосвязанными, хотя между компонентами стимула такая связь отсутствовала.

Перейдем ко второму этапу решения задачи: “от ощущения — к восприятию”. Он начинается с преобразования матрицы \mathbf{D} размером $M_s * M$ в таблицу элементов некоторого множества Z размером $Nr * M$. Элементами этого множества являются списки Z_{kr} номеров s объектов, у которых для k -го признака значение $d_k = \mathfrak{R}_r$. Это множество представляет всю информацию, содержащуюся в обучающей выборке в трансформированном и сжатом виде. Оно играет роль памяти модели с определенными свойствами. Особенность структуры множества Z иллюстрирует табл. 1, которая соответствует обучающей выборке из 20 объектов, характеризуемых 4 признаками и относящихся к двум классам, для случая $Nr = 3$ ($M_s = 20, M = 4, Mi = 2$). Номера объектов каждого класса имеют разное начертание.

Таблица 1: Множество Z .

r	Признаки			
	k=1	k=2	k=3	k=4
1	3 4 8 9 19	6 7 12 14 18 20	2 5 6 8 12 14 19 20	4 6 9 14 16 17
2	2 5 6 11 12 15 17 18 20	1 3 5 8 11 15 17	3 4 9 13 15 16 18	1 3 5 7 8 10 11 13 18 20
3	1 7 10 13 14 16	2 4 9 10 13 16 19	1 7 10 11 17	2 12 15 19

Множество Z позволяют оценить статистические характеристики объектов отдельных классов. Для объектов класса ω_i при каждом k сумма

$$\sum_{r=1}^{Nr} L_{kr}^i = N^i,$$

где L_{kr}^i — количество объектов в множестве Z_{kr}^i (мощность множества), N^i — общее число объектов класса. Учитывая, что некоторые множества могут быть пустыми, получим $0 \leq L_{kr}^i \leq N^i$. Частота объектов класса ω_i , у которых $d_k = \mathfrak{R}_r$, $r \in (1, Nr)$, равна $f_{kr}^i = L_{kr}^i/N^i$.

Величина f_{kr}^i приближенно описывает неизвестную кривую условной плотности вероятности компоненты q_k объекта класса ω_i , равную $P(\omega_i | q) \cong p(\omega_i | d_k)$. При $Nr \rightarrow \infty$ величина f_{kr}^i стремится к $p(\omega_i | q_k)$. Для объектов класса ω_i событие d состоит из полной группы независимых событий d_1, \dots, d_M . Тогда

$$P(\omega_i | d) = \sum_{k=1}^M p(\omega_i | d_k = \mathfrak{R}_r).$$

Отсюда следует:

$$P(\omega_i | q) = \frac{1}{M} \sum_{r=1}^M f_{kr}^i. \quad (2)$$

Здесь индекс r зависит от значения d_k . Максимальное значение $P(\omega_i | d)$ при всех $i \in (1, Mi)$ определяет расчетное значение i , равное

$$I(q) = \arg \max(P(\omega_i | q) | i \in (1, Mi)). \quad (3)$$

Эта формула позволяет найти класс объекта, который характеризуется набором значений r при каждом k . Для объекта, у которого c_k выходит за левую или правую границу отрезка $(c_{k,mi}, c_{k,ma})$, установленного по обучающей выборке, значение d_k принимается равным \mathfrak{R}_1 или \mathfrak{R}_{Nr} соответственно.

Величина $I(q)$ вычисляется для всего ансамбля матриц, соответствующих определенным параметрам Nr и α . Значение их варьируются в зависимости от параметров обучающей выборки. При вычислениях используется подход, который отражает существование достаточно независимых нейронных сетей мозга, участвующих

в обработке афферентной информации. Согласно ему решения находятся при нескольких значениях α , а затем выбирается то его значение, при котором результаты обучения являются оптимальными, а также устойчивыми [14]. Можно ожидать, что простота алгоритма и устойчивость результатов обеспечат минимальный риск переобучения.

7. Результаты расчетов

Эффективность предложенного метода была апробирована при решении двух известных задач из репозитория [15], которые рассматривались как задачи обучения. Одна из них “Iris” содержала данные по 4 количественным признакам 150 цветов, разделенных на три класса ($M_s = 150, M = 4, M_i = 3$). Задача “Wine” касалась 178 вин, химический состав которых описывался по 13 признакам; вина относились к трем классам ($M_s = 178, M = 13, M_i = 3$).

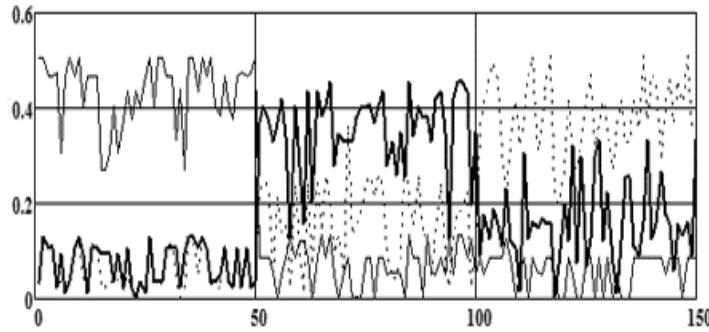


Рис. 1: Кривые зависимости вероятности объектов отдельных классов от их номера для задачи “Iris”.

Параметры дискретизации и расширения данных Nr и α_1 варьировались при расчетах. Вектор α рассматривался как случайная величина, компоненты которой, за исключением α_1 , равномерно распределены на отрезке $[0, b]$. Для каждой пары значений α_1 и b

рассматривались несколько случайных реализаций вектора α_1 , отличающихся начальным значением соответствующей выборки. Вероятности отдельных классов для всех объектов вычислялась по формуле (2).

Наилучшие результаты для задачи "Iris" получены при $Nr = 8$, $\alpha_1 = 0.05$, $b = 5$, когда ошибки обучения составили $\delta = 4,0\%$. Для этого случая на рис. 1 приведен результаты расчетов. (Номера объектов отдельных классов находятся в границах $1 \leq s \leq 50$, $50 < s \leq 100$ и $100 < s \leq 150$). Они показывают достаточно высокое качество обучения. Вычисления по той же схеме для исходной выборки ($\alpha_1 = 0$) дали ошибку $\delta = 11.3\%$. Ошибка в $4,0 - 4,7\%$, соответствующая неверной классификации 6 – 7 из 150 объектов, достаточно устойчива и наблюдается при значительных изменениях расчетных параметров. Она отмечалась при $5 \leq Nr \leq 8$, $0.5 \leq b \leq 5$. Аналогичные результаты были получены для задачи "Wine", где $\delta = 4,5\%$. Однако верхняя граница Nr для устойчивых результатов снизилась до 7.

8. Заключение

В работе предложен новый инструмент для решения задачи обучения в виде модели самоорганизующейся системы. Она обладает аналогами таких элементов мышления как ощущение и восприятие. Модель образована нейронными сетями, имеющими форму ветвящихся цепей элементов. В отличие от существующих сетей это универсальный вычислительный инструмент, использование которого не требует знаний о его внутреннем устройстве, а расчеты выполняются согласно единому алгоритму по простым расчетным зависимостям.

Модель реализует схему обработки информации в "живом процессоре", который решает задачи обучения на несколько порядков быстрее самых многообещающих ЭВМ, несмотря на относительно малую скорость ее обработки. Очевидна перспективность модели и теории ИС в части разработки универсальных блоков управления, а также нового типа компьютеров для решения задач искусственного интеллекта.

Список литературы

- [1] *Rosenblatt F.* Principles of Neurodynamics. Washington DC.: Spartan Books. 1962.
- [2] Информационный подход в междисциплинарной перспективе (материалы Круглого стола) // Вопросы философии. 2010. № 2. С. 84–112.
- [3] *Кузнецов Н.А., Любецкий В.А., Чернавский А.В.* О понятии информационного взаимодействия. 1: допсихический уровень // Информационные процессы. 2003. Т. 3. № 1.
- [4] *Иваницкий А.М.* Проблема “сознание и мозг” и искусственный интеллект // VIII Всероссийская научно-техническая конференция “Нейроинформатика-2006”: Лекции по нейроинформатике.- М.: МИФИ. 2008. С. 74–86.
- [5] *Величковский Б.М., Варданов А.В., Шевчик С.А.* Системная роль когнитивных исследований в развитии конвергентных технологий // Вестник Томского государственного университета. № 334. 2010. С. 186–191.
- [6] *Шац В.Н.* Непрерывноветвящаяся цепь как модель биологической цепи нейронов // Труды одиннадцатой национальной конференции по искусственному интеллекту с международным участием КИИ-2008. Т. 1. — М.: ЛЕНАНД. 2008. С. 164–170.
- [7] *Шац В.Н.* Применение модели информационной среды для решения задач классификации и обучения // Труды двенадцатой национальной конференции по искусственному интеллекту с международным участием. Т. 2. — М.: Физматлит. 2010. С. 22–30.
- [8] *Шац В.Н.* О модели воздействия информации на группу // Социология: методология, методы, математическое моделирование. 2010. № 30. С. 181–194.
- [9] *Шац В.Н.* Стохастический метод решения задач классификации и обучения // Стохастическая оптимизация в информатике. 2011. Т. 7. С. 257–268.

- [10] Шац В.Н. Вычислительная модель модуля нервной системы // Сборник научных трудов научно-технической конференции “Нейроинформатика-2011”. Ч. 2. 2011. С. 229–238.
- [11] Дубровский Д.И. Сознание, мозг, искусственный интеллект. М.: ИД “Стратегия - Центр”, 2007. 272 с.
- [12] Чораян О.Г. Естественный интеллект (физиологические, пси-хологические и кибернетические аспекты). Ростов-на-Дону: 2002. 112 с.
- [13] Вапник В.Н., Червоненкис А.Я. Теория распознавания образов (статистические проблемы обучения). — М.: Наука. 1974. 416 с.
- [14] Границин О.Н., Поляк Б.Т. Рандомизированные алгоритмы оценивания при почти произвольных помехах. — М.: Наука. 2003. 291 с.
- [15] Asuncion A., Newman D.J. UCI Machine Learning Repository. Irvine CA: University of California, School of Information and Computer Science. 2007.