

# РАННЕЕ ОБНАРУЖЕНИЕ АНОМАЛИЙ С ПОМОЩЬЮ МНОГОЗНАЧНОЙ АССОЦИАТИВНОЙ ПАМЯТИ

Д.Ю. Максимов

*Институт проблем управления им. В.А. Трапезникова РАН*

Россия, 117997, Москва, Профсоюзная ул., 65

E-mail: jhanjaa@ipu.ru

**Ключевые слова:** многозначные нейронные сети, прогнозирование устойчивости.

**Аннотация:** Многозначные нейронные сети обобщают аналогичную нечеткую конструкцию на случай решеточных значений весов и переменных. В этом случае в формулах используются решеточные операции вместо суммы, произведения и Т-нормы. Однако на решетке дополнительно можно определить алгебраические операции внешним образом. В докладе рассматривается способ такого определения, когда в качестве значений весов и переменных берутся куски графика некоторого модельного процесса, что используется для прогнозирования его устойчивости.

## 1. Введение

Нечеткое моделирование неопределенности весьма бедно: вычисления оперирует только линейно упорядоченными переменными, которые в действительности могут быть неупорядоченными: например, «и да, и нет» и «ни да, ни нет». Кроме того, лингвистические оценки переводятся в числовые значения не однозначно определенным способом.

Ассоциативная память как частный случай нейронной сети, в которой веса и переменные принимают значения в решетке [2], рассматривалась в [9–11]. Это решеточно-значное расширение соответствующих нечетких понятий [4, 8]. В этом случае, все переменные и веса упорядочены не линейно, как в нечетком случае, а лишь частично [2]. Такой подход позволяет работать с лингвистическими переменными в нейронных сетях напрямую, без неоднозначных методов фаззификации/дефаззификации.

В этом докладе приводится общая алгебраическая конструкция, операции которой могут быть использованы вместо нечетких, в частности, в формулах для многозначной ассоциативной памяти. Показывается, что состояние системы может оцениваться не только числом (как в нечетком случае) или лингвистической переменной (как в предыдущих работах), но также объектами более общей природы – частями экспериментальной кривой, и что такие объекты целиком могут быть весами и переменными в вычислениях. В сложных технических системах использование таких объектов вместо чисел может быть более подходящим.

В разд. 2. вводятся необходимые определения и приводится результат, устанавливающий условия возможности использования такой алгебраической конструкций. В разд. 3. прогнозируется устойчивость модельного процесса с помощью многозначной ассоциативной памяти, в которой веса и переменные являются некоторыми вещественными функциями. В заключение подводятся итоги.

## 2. Алгебраические результаты

Умножение/сложение на решетке можно задать приемлемым для приложений способом, если эта решетка  $M$  является еще и  $l$ -моноидом или  $l$ -группой [2]:

**Определение 1.** Решетка  $M$  с умножением называется  $l$ -моноидом, если умножение является моноидальной операцией, т.е.

- умножение удовлетворяет условию изотонности:

$$\text{если } a \leq b, \text{ то } xa \leq xb \text{ и } ax \leq bx, \forall a, b, x \in M;$$

- умножение ассоциативно;
- умножение обладает нейтральным элементом ("1"), таким, что:

$$x1 = 1x = x; \forall x \in M;$$

и умножение дистрибутивно относительно объединения:

$$a(b \vee c) = ab \vee ac; \text{ и } (a \vee b)c = ac \vee bc; \forall a, b, c \in M$$

$l$ -группа – частный случай  $l$ -моноида; в этом случае для любого элемента существует обратный ему относительно моноидального умножения.  $l$ -группы – неограничены, и их пример, используемый в рассматриваемом приложении – коммутативная аддитивная  $l$ -группа  $C[0, 1]$  непрерывных вещественных функций на отрезке  $[0, 1]$  с поточечными операциями без нулей на этом отрезке.

Такие объекты можно использовать вместо чисел в вычислениях на решетках, т.е. на частично-упорядоченных множествах. Однако, чтобы это можно было сделать в нейронных сетях с подобными весами и переменными, должно выполняться дополнительное условие.

Именно, в [9] доказано, что используемая решетка должна быть *резидуальной* [3], т.е. в  $l$ -моноиде должно быть определено деление [2]:

**Определение 2.** *Резидуальной решеткой* называется алгебра  $(L, \vee, \wedge, \cdot, 1, \rightarrow, \leftarrow)$ , удовлетворяющая следующим условиям:

- $(L, \vee, \wedge)$  – решетка;
- $(L, \cdot, 1)$  – моноид;
- $(\rightarrow, \leftarrow)$  – пара резидуалов операции  $\cdot$ , что означает:

$$\forall x, y \in L : x \cdot y \leq z \Leftrightarrow y \leq x \rightarrow z \Leftrightarrow x \leq z \leftarrow y$$

В этом случае, операция  $\cdot$  сохраняет порядок по каждому аргументу и для любых  $a, b \in L$  в каждом из множеств  $\{y \in L | a \cdot y \leq b\}$  и  $\{x \in L | x \cdot a \leq b\}$  есть наибольший элемент ( $a \rightarrow b$  и  $b \leftarrow a$  соответственно).

Используемая далее  $l$ -группа непрерывных вещественных функций на отрезке с поточечными операциями удовлетворяет этому условию.

### 3. Прогнозирование аномалий

Существует задача раннего обнаружения аномалий (например [12]) технологических процессов. Для этого, в Лаборатории Касперского разработано программное обеспечение, использующее импульсные нейронные сети [5–7]. В данной работе представлен более простой способ обнаружения аномалий с помощью многозначной ассоциативной памяти.

Рассмотрим ассоциативную память, изображенную на рис. 1.

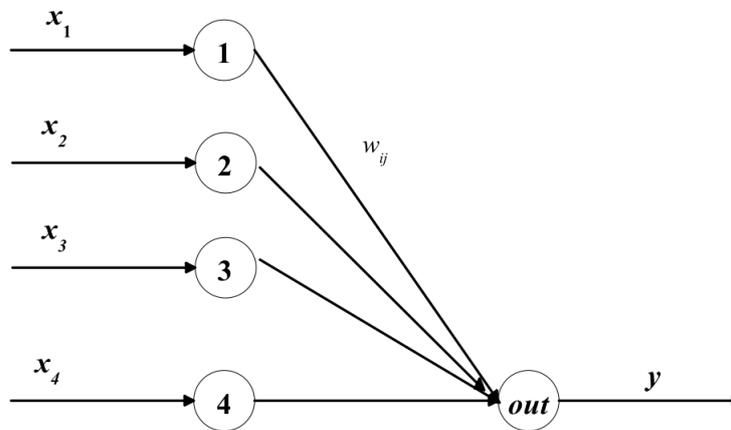


Рис. 1. Двухслойная ассоциативная память

Веса и переменные принимают значения в  $l$ -группе  $C[0, 1]$  непрерывных вещественных функций на отрезке  $[0, 1]$  с поточечными операциями без нулей на этом отрезке. Эта память способна хранить некоторое множество паттернов «вход–выход», где выходом является часть графика функции, лежащая на этом графике правее входов. По этому множеству можно вычислить весовую матрицу и использовать ее потом для классификации произвольного входного паттерна, т.е. для прогнозирования поведения процесса на удаленном от входов участке. Для простоты используются положительные функции.

Рассмотрим модельный процесс, в котором на несущую функцию  $a \cdot \sin(kx + t)$  ( $t$  – время) накладывается шум и три модулирующие волны со случайно выбранными фазами:  $\sum_{i=1}^3 a_i \cdot \sin(k_i x + t + \varphi_i)$ , что соответствует линейной модели «волны-убийцы» [1]. Такие экстремально высокие волны (или глубокие провалы) встречаются в океане. В линейной модели амплитуды модуляций могут в некотором месте складываться так, что возникает всплеск суммарной амплитуды процесса. Такой аномальный всплеск представляет опасность и должен быть спрогнозирован.

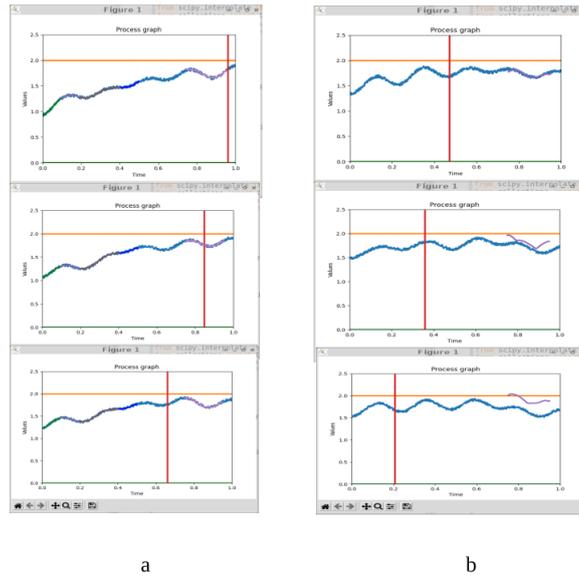


Рис. 2. Последовательные снимки обучающей выборки графика модельного процесса с выходным сплайном, вычисленным по этой выборке, (a) Продолжение процесса после обучающей выборки с вычисленными выходными сплайнами, (b)

На начальном участке выбранного окна процесса выбираются четыре попарно пересекающихся интервала равной длины, на которых процесс интерполируется сплайнами. Эти сплайны являются четырьмя входными значениями, каждое из которых подается на свой вход ассоциативной памяти. Количество и длина интервалов подбиралась экспериментально так, чтобы возмущения лучше отлавливались и при этом не сглаживались. В конце окна выбирается такой же интервал для выходного сплайна. Делая снимки кривой со сдвигом окна по времени, получаем набор таких входных и выходных паттернов.

При таком задании входов и выходов у нас нет возможности подбирать обучающую выборку для того, чтобы выполнялось условие возможности сохранения заданного множества [9], поэтому реальный выход может быть больше в общем случае [9] (рис. 2(a)):

$$(1) \quad y_j \geq \bigvee_{i \in N} \{x_i \cdot w_{ij}\}.$$

Кроме того, поскольку в используемой  $l$ -группе общая формула вычисления весов имеет вид:  $w_{ij}^* \equiv \bigwedge_{k \in P} (x_i^k \rightarrow y_j^k) = \bigwedge_{k \in P} (y_j^k / x_i^k)$  для положительно-определенных функций ( $P$  – множество обучающих паттернов), эти веса позволяют вычислять выход только на монотонной части графика. При изменении типа монотонности (возрастания или убывания) предсказание остается в соответствии исходному типу, по которому было обучение, и поэтому возникают большие расхождения. Более того, поскольку в (1) зависимость между входами и выходом линейная, то прогнозировать без больших расхождений удастся только на линейных участках сглаженного графика процесса (в данном случае на приблизительно линейной части несущей функции –  $\sin$ ). При выходе на нелинейную часть возникают расхождения рис. 2(b) .

## 4. Заключение

В этой работе показано, что в вычислениях, обобщающих нечеткие, можно использовать, вместо вещественных чисел, элементы объектов более общей природы – в частности, групп в случае, если они решеточно упорядочены. При этом, в ассоциативной памяти веса и переменные должны быть элементами резидуальной решетки для того, чтобы с ними можно было оперировать.

Было выполнено прогнозирование аномалий поведения модельного процесса с модулирующими возмущениями. Получается приемлемый прогноз, но его дальность зависит от затухания возмущений, от их количества и от относительной линейности прогнозируемого участка кривой. Поэтому оценить точность прогноза можно будет только на реальном процессе.

## Список литературы

1. Слюняев А. В., Пелиновский Е. Н. Волны-убийцы: мифы и реальность // Природа. 2021. № 10. С. 10-25.
2. Birkhoff G. Lattice Theory. Rhode Island: Providence, 1967. *русс. перев. Биркгоф Г.* Теория решеток. М.: Наука, 1984.
3. Blount K., Tsinakis C. The structure of residuated lattices. // Int. J. Algeb. Comput., 2003. No. 13. P. 437–461.
4. Glykas M. (ed.) Fuzzy Cognitive Maps Advances in Theory, Methodologies, Tools and Applications // Stud. in Fuzz. and Soft Comp. Vol. 247. Berlin, Heidelberg: Springer, 2010.
5. Kaspersky Machine Learning. <https://neuro.kaspersky.ru/> (дата обращения: 06 марта 2023 г.).
6. Kiselev M.V. A Synaptic Plasticity Rule Providing a Unified Approach to Supervised and Unsupervised Learning // Proc. of IJCNN-2017. Anchorage, 2017. P. 3806–3813.
7. Kiselev M.V. A Spiking Neural Network Structure Implementing Reinforcement Learning. // arXiv.org, 2022. Doi 10.48550/ARXIV.2204.04431. <https://arxiv.org/abs/2204.04431> (дата обращения: 06 марта 2023 г.).
8. Liu P., Li H. Fuzzy neural network theory and application // Ser. in Mach. Perc. and Artif. Int. Vol. 59. London: W. Sci. Pub. Co. Pte. Ltd., 2004.
9. Maximov D. Multi-Valued Neural Networks II: A Robot Group Control // Adv. in Sys. Sci. and App. 2020. Vol. 20, No. 4. P. 70–82.
10. Maximov D., Goncharenko V. I., Legovich Yu. S. Multi-Valued Neural Networks I: A Multi-Valued Associative Memory // Neur. Comp. and App. 2021. Vol. 33, No. 16. P. 10189–10198.
11. Maximov D., Goncharenko V. I., Legovich Yu. S. Correction to: Multi-valued neural networks I: a multi-valued associative memory // Neural Computing and Applications. 2023. Vol. 35, No. 24. P. 18087–18088.
12. Shalyga D., Filonov P., Lavrentyev A. Anomaly Detection for Water Treatment System based on Neural Network with Automatic Architecture Optimization // arXiv.org, 2018. <https://arxiv.org/abs/1807.07282> (дата обращения: 06 марта 2023 г.).