

# ГИБРИДНЫЕ МОДУЛЯРНЫЕ НЕЙРОННЫЕ СЕТИ<sup>1</sup>

УДК 339.13

**Алексей Николаевич Аверкин**,  
к. ф.-м. н., ведущий научный сотрудник  
отдела интеллектуальных систем  
Вычислительного центра им. А.А.  
Дородницына ФИЦ «Информатика и  
управление» РАН  
Тел.: (499) 135 40 98  
Эл. почта: averkin2003@inbox.ru

В работе рассматриваются гибридные нейросетевые подходы к прогнозированию временных рядов, в том числе методы, основанные на нечетких моделях, такие как ANFIS модели, а также предлагается гибридный нейросетевой подход, основанный на модулярных нейронных сетях.

**Ключевые слова:** прогнозирование, временные ряды, ANFIS, модулярные нейронные сети.

**Alexey N. Averkin**,  
PhD, associated professor of the Academic  
Department of Informatics Plekhanov  
Russian University of Economics (PRUE),  
chief researcher of intelligent department  
systems of Dorodnicyn Computing Center  
of FRC «Informatics and control of RAS»  
Tel.: (499) 135 40 98  
E-mail: averkin2003@inbox.ru

## HYBRID MODULAR NEURAL NETWORKS

In this paper considered hybrid neural networks for time series forecasting and methods based on fuzzy models, such as ANFIS models and we also suggest a hybrid neural network model based on modular neural networks.

**Keywords:** forecasting, time series, ANFIS, modular neural networks.

## 1. Введение

В последние годы прогнозирование временных рядов является одной из самых популярных областей исследований. Основываясь на исторических данных, ученые строят прогнозы на будущее. Примером использования исторических данных может служить прогнозирование фондовых рынков, энергопотребления, экономических показателей и т. д. Прогнозирование является неотъемлемой частью жизни современного общества, без него невозможно планировать будущие расходы или экономические планы развития.

Изменчивость производственно-экономических отношений, неустойчивость, концептуальная непоследовательность и неполнота законодательной базы, регулирующей эти отношения, приводят к тому, что временные ряды, представляющие многие производственные, экономические и социально-экономические процессы, имеют короткую актуальную часть. Многие новые процессы производственной и социальной сферы представляются физически короткими временными рядами, поскольку ранее не являлись предметом статистического учёта.

Но в современной ситуации, когда знания накапливаются огромными темпами, а экономическая ситуация меняется практически ежедневно, становится затруднительным осуществлять качественные прогнозы в подобных ситуациях. Для решения таких задач требуется разработка новых, гибридных моделей прогнозирования на основе методов искусственного интеллекта и нечеткой логики.

## 2. Обзор гибридных методов прогнозирования, основанных на ANFIS моделях

Типовые процедуры обучения нейронных сетей могут быть применены для настройки ANFIS-сети, так как в ней используются только дифференцируемые функции. Обычно применяется комбинация градиентного спуска в виде алгоритма обратного распространения ошибки и метода наименьших квадратов. Алгоритм обратного распространения ошибки настраивает параметры antecedent правил, т. е. функций принадлежности. Методом наименьших квадратов оцениваются коэффициенты заключений правил, так как они линейно связаны с выходом сети. Каждая итерация процедуры настройки выполняется в два этапа. На первом этапе на входы подается обучающая выборка, и по невязке между желаемым и действительным поведением сети итерационным методом наименьших квадратов находятся оптимальные параметры узлов четвертого слоя. На втором этапе остаточная невязка передается с выхода сети на входы, и методом обратного распространения ошибки модифицируются параметры узлов первого слоя. При этом найденные на первом этапе коэффициенты заключений правил не изменяются. Итерационная процедура настройки продолжается пока невязка превышает заранее установленное значение. Для настройки функций принадлежности кроме метода обратного распространения ошибки могут использоваться и другие алгоритмы оптимизации, например метод Левенберга – Марквардта.

На сегодняшний момент существует большое количество различных подходов к нейро-нечеткому прогнозированию временных рядов, в частности для обучения подобных сетей применяются генетические алгоритмы, методы роевой оптимизации, а также различные гибридные методы. Китайские ученые [1] представили собственную модель прогнозирования финансовых потоков в банковской сфере с использованием модифицированного алгоритма роевой оптимизации, который называется APAPSO (Adaptive Population Activity PSO). Ввиду того, что использование традиционных методов не дает стабильных результатов прогнозирования, ученые предложили гибридный алгоритм обучения на основе APAPSO алгоритма в сочетании с

<sup>1</sup> Работа выполнена при финансовой поддержке РФФИ (16-37-50023 и 14-07-00603).

методом наименьших квадратов. В сравнительных экспериментах, разработанный алгоритм сравнивался со стандартным методом обратного распространения ошибки в сочетании с методом наименьших квадратов (LMS), а также с традиционным методом роевой оптимизации-LMS.

Для того чтобы избежать проблему, когда алгоритм попадает в локальный минимум и повысить его сходимости, метрическая функция популяции определяется на основании сходимости алгоритма PSO. Использование APAPSO алгоритма в соответствии с соотношением между разнообразием популяции и скоростью движения частиц. В данном алгоритме улучшен PSO алгоритм, веса настраиваются адаптивно на основе изменения функции разнообразия популяции, с тем чтобы улучшить разнообразие роя частиц и способность выходить алгоритму из локальных оптимальных решений.

Результаты продемонстрировали рост скорости оптимизации, по сравнению с традиционными алгоритмами, а также рост точности прогнозирования.

Ученые из США и Ирана [2] представили совместную работу по исследованию в области прогнозирования валютной пары доллар/иена. В своей работе исследователи сравнивают производительность ANFIS модели с разработанными ранее моделями традиционных нейронных сетей. Средние RMSE (табл. 1) и результаты лучше для ANFIS подхода, чем для Сугено-Ясукава, ИНС или нескольких подходов регрессии. Как видно в табл. 1, средняя квадратичная ошибка (RMSE) меньше всего у модели, основанной на ANFIS.

Исследователи пришли к выводу, что хоть и разница между традиционной ИНС и ANFIS системой невелика, но ANFIS система представляет собой гораздо более понятную для

человека систему и более удобна в использовании.

Индийские ученые [3] предложили гибридную модель прогнозирования, основанную на интеграции ANFIS и иммунного алгоритма для прогнозирования индийского фондового рынка. Для создания эффективной модели прогнозирования, ученые решили использовать искусственный иммунный алгоритм для настройки параметров функции принадлежности системы нечеткого вывода. В качестве входных данных для тестирования системы использовались данные дневных закрытий торгов на Национальной фондовой бирже Индии (NSE), а также известные технические индикаторы. На выходе получали прогноз будущего значения индекса NSE.

**Алгоритм клонального отбора.** Искусственный иммунный алгоритм является новым методом интеллектуальных вычислений, основанный на биологической иммунной системе человека. В данном исследовании ученые использовали иммунный алгоритм, называемый клональным отбором. Данный алгоритм работает как генетический алгоритм. Он симулирует естественные биологические клетки. Антитела закреплены на В-клетке, которая распознает антигены, поступающие из внешней среды. Также данный алгоритм клонирует больше антител с наиболее приспособленными антителами для уничтожения антигена. Как результат, иммунная система продуцирует больше антител, чем антигенов. Базовые элементы в данном алгоритме – это антитела и антигены. В ANFIS антигены представляют входные данные с рынка акций, а антитела представляют собой нечеткие правила. Алгоритм применяется для обучения нечетких правил с наилучшей приспособленностью к данным рынка акций.

Результаты экспериментов сравнивались с другими моделями на основе мягких вычислений и фактическими данными с торгов. В итоге результаты эксперимента показали, что предложенная модель прогнозирования дала значительно более точные результаты прогнозирования в сравнении с традиционными моделями.

Несмотря на большое количество разнообразных подходов к обучению сетей, модификацией архитектуры и гибридизации нескольких методов, везде в основе лежат ANFIS модели. Каждое исследование продемонстрировало превосходство нейро-нечеткого подхода над традиционными нейронными сетями и другими статистическими методами.

### 3. Модулярные нейронные сети в задачах прогнозирования


Самоорганизующиеся карты Кохонена (SOM) представляют собой алгоритм обучения без учителя для создания сохраняющих топологию отображений многомерных векторных данных в маломерные пространства карты и являются мощным инструментом, используемым во многих областях, таких как извлечение данных, анализ, классификация и визуализация. SOM применяются в различных областях, таких как веб-поиск, биоинформатика, финансы и их значимость продолжает расти. Однако, несмотря на растущую значимость, обычные SOM и большинство их расширений могут работать только с векторизованными данными. Если необходимо работать с не векторными данными, то нужно векторизовать данные заранее или изменить саму SOM так чтобы она была применима к этому типу данных. Таким образом, обобщающие семейства SOM это неизбежная задача описания SOM независимо от типа данных.

Идея модульной [4] SOM проста: каждый векторный модуль обычной SOM заменяется на обучаемый функциональный модуль, такой как нейронная сеть. Таким образом, архитектура mnSOM представляет собой соединение функциональных модулей на размещенных на решетке (см. рисунок). Функциональные

Таблица 1

Средняя квадратичная ошибка различных моделей прогнозирования

| Модель прогнозирования  | Правила | Итерации | RMSE   |
|-------------------------|---------|----------|--------|
| Множественная регрессия | –       | 10       | 7,9221 |
| Нейронная сеть          | –       | 10       | 2,8082 |
| Сугено-Ясукава          | 6       | 10       | 4,8290 |
| ANFIS                   | 7       | 10       | 2,6301 |



Модульная нейронная сеть с модулями из многослойных персептронов

модули могут быть спроектированы так, чтобы удовлетворять конкретной задаче, в то время как основа алгоритма SOM остается нетронутой. Эта обобщенная стратегия обеспечивает как высокую степень гибкости устройства и высокую надежность SOM, поскольку mnSOM позволяет выбрать функциональные модули из огромного числа нейросетевых архитектур, которые предложены на данный момент и в тоже время последовательный метод расширения обеспечивает состоятельность теории, т.е. статистические свойства результатов. Кроме того, эта стратегия предоставляет функциональные возможности обработки данных для всех узловых единиц SOM. Таким образом, mnSOM может быть использована для объединения обработчиков данных после обучения. Это еще одно преимущество mnSOM.

В чистом виде самоорганизующиеся карты не подходят для прогнозирования, но благодаря проведенным модификациям можно получить сеть, способную давать качественный прогноз. Далее приведены некоторые типы модификаций для прогнозирования.

VQTAM – это модификация самоорганизующихся карт Кохонена, которая может быть применена для идентификации динамических систем. Вектор входных признаков  $u(t)$  данной сети разделен на две части:  $x^{in}(t)$ ,  $x^{out}(t)$ . Первая часть входных признаков  $x^{in}(t)$  содержит информацию о входах динамического объекта и его предыдущих выходах. Вторая часть вектора входных признаков  $x^{out}(t)$  содержит информацию о предполагаемом выходе данного динамического объекта, соответс-

твующем входам  $x^{in}(t)$ . Вектор весов разделен аналогичным способом [5]. Таким образом  $x(t) = \begin{pmatrix} x^{in}(t) \\ x^{out}(t) \end{pmatrix}$  и

$w_i(t) = \begin{pmatrix} w_i^{in}(t) \\ w_i^{out}(t) \end{pmatrix}$ , где  $w_i(t)$  – вектор весов  $i$ -го нейрона,  $w_i^{in}(t)$  часть вектора весов, содержащая информацию о входах процесса, а  $w_i^{out}(t)$  – часть вектора весов, содержащая информацию о выходах процесса. Первая часть вектора входных признаков содержит информацию о входах процесса и его предыдущих выходах  $x^{in}(t) = (y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u))$ , где  $n_y < T$ ,  $n_u < T$ .

Вторая часть вектора входных признаков  $x^{out}(t) = y(t)$  содержит информацию о предполагаемом выходе данного процесса, соответствующем входам  $x^{in}(t)$ .

Каждый пример выборки состоит из пары векторов  $(y(t), u(t))$  и выборка должна содержать не менее  $\max(n_u, n_y)$  примеров. Вектора  $y(t)$  представляют собой вектора входов процесса в момент времени  $t$  а  $u(t)$  – вектора выходов этого процесса в тот же момент времени.

После подачи на вход сети очередного входного вектора  $x(t)$ , составленного из нескольких примеров обучающей выборки, нейрон-победитель определяется только по вектору  $x^{in}(t)$

$$i^*(t) = \arg \min_i \|x^{in}(t) - w_i^{in}(t)\|,$$

где  $i^*(t)$  – номер нейрона-победителя на шаге  $t$ .

Для изменения весов может быть применено модифицированное правило изменения весов для обычной SOM:

$$\Delta w_i^{in}(t) = \alpha(t)h(i^*, i, t)[x^{in}(t) - w_i^{in}(t)],$$

$$\Delta w_i^{out}(t) = \alpha(t)h(i^*, i, t)[x^{out}(t) - w_i^{out}(t)],$$

где  $0 < \alpha(t) < 1$  – скорость обучения сети, а  $h$  – функция соседства нейрона  $i$  и  $i^*$ . В качестве функции соседства  $h(i^*, i, t)$  может быть выбрана, например, Гауссова функция

$$h(i^*, i, t) = \exp \left\{ -\frac{\|r_i(t) - r_{i^*}(t)\|^2}{2\sigma^2(t)} \right\},$$

где  $r_i(t)$  и  $r_{i^*}(t)$  – положения на карте нейронов  $i$  и  $i^*$  соответственно,  $\sigma(t) > 0$  – определяет радиус функции соседства на шаге  $t$ . После выбора нейрона-победителя  $i^*$  выход этого нейрона окрашивается вектором  $w_{i^*}^{out}(t)$ .

В режиме работы на вход VQTAM подается только вектор  $x^{in}(t)$ , для которого определяется нейрон-победитель и его выход окрашивается  $w_{i^*}^{out}(t)$ . Вектор  $w_{i^*}^{out}(t)$  может быть интерпретирован, как предсказанный выход  $\hat{y}(t)$  процесса объекта в момент времени  $t$ .

Нейронная модульная сеть [7], где в качестве модулей применены сети типа VQTAM (сеть SOMxVQTAM), обучается с помощью комбинации алгоритмов обучения модульной сети, а также по алгоритму обучения сетей типа VQTAM. На этапе обучения после подачи очередного обучающего примера на вход сети вычисляются выходы всех сетей типа VQTAM, использованных в качестве модулей, далее определяется модуль-победитель как модуль, выход которого минимально удален от ожидаемого выхода сети на представленном обучающем примере. После этого происходит подстройка весов сети типа VQTAM, находящейся в модуле-победителе, подстройка весов происходит по алгоритму подстройки весов сетей типа VQTAM. Далее набор весов данной сети рассматривается, как один весовой вектор модуля-победителя модульной карты, и происходит подстройка весов модульной карты по стандартным алгоритмам подстройки весов, применяемых при обучении нейронных карт Кохонена.

В случае с модульной сетью, где в качестве модулей применены сети типа RSOM (сеть SOMxRSOM), так

Таблица 2

| №  | Название алгоритма | SMAPE |
|----|--------------------|-------|
| 1  | Wildi              | 19,9  |
| 2  | Andrawis           | 20,4  |
| 3  | Vogel              | 20,5  |
| 4  | D'yakov            | 20,6  |
| 5  | Noncheva           | 21,1  |
| 6  | Rauch              | 21,7  |
| 7  | Luna               | 21,8  |
| 8  | Lagoo              | 21,9  |
| 9  | Wichard            | 22,1  |
| 10 | Gao                | 22,3  |
| -- | SOMxVQTAM          | 23,4  |
| 11 | Puma-Villanueva    | 23,7  |
| -- | VQTAM              | 23,9  |
| 12 | Autobox (Reilly)   | 24,1  |
| 13 | Lewicke            | 24,5  |
| 14 | Brentnall          | 24,8  |
| 15 | Dang               | 25,3  |
| 16 | Pasero             | 25,3  |
| 17 | Adeodato           | 25,3  |
| -- | RSOM               | 25,7  |
| 18 | undisclosed        | 26,8  |
| 19 | undisclosed        | 27,3  |
| -- | SOMxRSOM           | 27,9  |

же полученной в ходе данной работы, обучение происходит аналогичным образом.

Для экспериментов и сравнительного анализа алгоритмов сети типов VQTAM, RSOM, SOMxVQTAM и SOMxRSOM были запущены на выборках, использовавшихся в 2008 году для определения победителей на соревновании нейросетевых алгоритмов прогнозирования. Результаты этого соревнования были использованы в данном исследова-

нии, так как присутствует детальное описание методики определения места в таблице результатов, так же в соревновании приняло участие большое число различных алгоритмов прогнозирования, присутствует описание работы большинства из этих алгоритмов, а также выборки данных, на которых производилось тестирование этих алгоритмов, что позволяет провести сравнительный анализ описываемых в данной статье нейросетевых алгоритмов с другими передовыми методиками. Для определения места в таблице результатов организаторами данного соревнования было предложено провести прогноз на 56 шагов для каждой из 111 выборок. Для каждого из полученных прогнозов считалась симметричная средняя абсолютная процентная ошибка. Затем место в табл. 2 определялось по средней по всем 111 выборкам ошибке.

## 5. Заключение

Проведенное исследование показывает, что в современной обстановке на передний план выходят гибридные методы прогнозирования временных рядов, в частности с применением методов нечеткой логики, таких как ANFIS, подходы где используются гибридные алгоритмы обучения существенно превосходят аналоги, в которых используются традиционные методы обучения. Также, исследования в области модулярных нейронных сетей показали,

что данные методы имеют большой потенциал для применения их в прогнозировании, поэтому имеет смысл продолжить исследования в данном направлении.

## Литература/References

1. Wang, J.-S.; Ning, C.-X. ANFIS Based Time Series Prediction Method of Bank Cash Flow Optimized by Adaptive Population Activity PSO Algorithm. *Information* 2015, 6, 300–313.
2. Alizadeh M. et al. Forecasting Exchange Rates: A Neuro-Fuzzy Approach // *IFSA/EUSFLAT Conf.* – 2009. – С. 1745–1750.
3. Gunasekaran, M. and Ramaswami, K.S., A Fusion Model Integrating ANFIS and Artificial Immune Algorithm for Forecasting Indian Stock Market (June 22, 2011). *Journal of Applied Sciences*, 11(16): pp. 3028–3033.
4. Tokunaga et al., 2009] Tokunaga K., Furukawa T. Modular network SOM – *Neural Networks*. №22, 2009. Pp 82–90.
5. Koskela T. *Neural network methods in analyzing and modelling time varying processes* – Espoo, 2003. Pp. 1–72.
6. Lotfi A., Garibaldi J. In *Applications and Science in Soft Computing*, *Advances in Soft Computing Series* Springer, 2003. Pp. 3–8.
7. A. Averkin, V. Albu, Veaceslav, S. Ulyanov and others. Dynamic object identification with SOM-based neural networks. In: *Computer Science Journal of Moldova*, 2014, nr. 22 1/64, pp. 110–126.