



## ПРИМЕНЕНИЕ МЕТОДА ГРУППОВОГО УЧЕТА АРГУМЕНТОВ В СИНТЕЗЕ СИГМОИДНЫХ НЕЙРОННЫХ СЕТЕЙ С УЧИТЕЛЕМ

Хомич Андрей Владимирович <sup>1)</sup>, Жуков Леонид Александрович <sup>2)</sup>

<sup>1)</sup> Аспирант, 660049, Россия, г. Красноярск, пр. Мира, 82, Сибирский государственный технологический университет, supremum76@rambler.ru

<sup>2)</sup> Доцент, Россия, г. Красноярск, пр. Мира, 82, Сибирский государственный технологический университет, zhukov\_l@rambler.ru, <http://zhukov.wallst.ru>

**Резюме:** Рассматривается целесообразность применения метода группового учета аргументов (МГУА) в синтезе сигмоидных нейронных сетей с учителем. Проведено сравнение эффективности двух вариантов МГУА использующие входные переменные на каждом и только на первом раунде селекции. Эффективность предлагаемых методов оценивается экспериментально на практических задачах.

**Ключевые слова:** Искусственная нейронная сеть, Эволюционные алгоритмы, МГУА.

### 1. ВВЕДЕНИЕ

Существуют практически важные задачи, в которых применение методов нейроинформатики требует использование нейронных сетей (НС) содержащих сотни и более нейронов (возможно с сильно разреженной структурой межнейронных связей). Иногда имеющийся объем данных недостаточен для качественного обучения сетей существующими методами. Бывает и так, что при решении задачи оба эти фактора присутствуют одновременно. Недостаток данных в совокупности с требуемой сложностью сетей приводит к высокой ошибке обобщения. То есть обученные сети, демонстрирующие малый процент ошибок на обучающих примерах, показывают высокий процент ошибок на тестовых примерах [3][4]. В тоже время, требование к количеству и качеству данных существенно зависит от выбранной схемы связи между нейронами. Структура сети выступает в роли регуляризирующего фактора.

Существуют исследования, в которых для синтеза НС используются методы эволюционного поиска [6][2][5]. В частности эволюционно оптимизируется структура НС с целью минимизировать ошибку обобщения [2][5]. При применении эволюционных алгоритмов возникает проблема больших вычислительных затрат. Поэтому остается актуальной задача разработки эффективных методов эволюционного поиска и их адаптации к задаче синтеза искусственных НС. В частности

видится весьма перспективной разработка операций скрещивания, позволяющих эффективно объединять «опыт» двух или более НС. Эволюционные алгоритмы условно можно разделить на эволюционные стратегии, генетические алгоритмы (ГА) и генетическое программирование (ГП). Для оптимизации структуры НС применяются ГА и ГП. При использовании ГА необходимо представлять объект оптимизации в виде строки. Генетическое представление НС может быть как прямым, в виде вектора атрибутов, так и с использованием специальных грамматик. ГА в процессе своей работы производит мутацию и скрещивание строк. При скрещивании создается строка, составленная из фрагментов двух других строк. В ГА при скрещивании взаимосвязи между элементами строк не анализируются. Например, в случае оптимизации НС не анализируются взаимосвязи между их элементами. ГП используется для создания программ представленных в виде дерева вычислений простых функций. Часто такие программы кодируются некоторым упрощенным Lisp-подобным языком. При конструировании НС с помощью ГП отпадает необходимость их представления в виде строк. Скрещивание в ГП реализовано как обмен поддеревьями функций между двумя программами. Однако в ГП при скрещивании программ также не анализируются взаимосвязи между их подпрограммами. Структура и веса оптимальной НС, а также

любого ее фрагмента (подсети), зависят от свойств входных и требуемых выходных сигналов. Каждая условно выделенная подсеть НС оптимизирует свои свойства с учетом характеристик взаимодействующих с ней других подсетей, то есть в зависимости от контекста. При простом обмене частями между двумя НС полезные свойства этих частей могут потеряться, так как изменяется контекст. Отсутствие анализа взаимосвязей снижает эффективность перебора вариантов НС. Решением проблемы может служить введение методов сохраняющих «опыт» объединяемых сетей. Примером может служить способ генерации частных описаний в методе группового учета аргументов (МГУА) [1].

МГУА по сути своей является эволюционным алгоритмом. Здесь имеются популяция (частные описания), эпохи (ряды), скрещивание и селекция. Известны приложения МГУА к задаче синтеза НС [7][8]. В этих исследованиях используются сети с полиномиальными функциями активации нейронов. Нейроны в таких сетях вычисляют полином от двух переменных. В данной работе предлагаются методы синтеза искусственных НС использующие нейроны с сигмоидной функцией активации. Такие сети используются более широко. Явных ограничений на количество принимаемых нейроном сигналов не накладывается.

## 2. СИНТЕЗ НЕЙРОННЫХ СЕТЕЙ С СИГМОИДНОЙ ФУНКЦИЕЙ АКТИВАЦИИ НЕЙРОНОВ

В многорядном (пороговом) МГУА [1] на вход подается некоторый вектор входных переменных  $x = x_1, x_2, \dots, x_n$ . На первом ряду селекции образуются «частные описания», объединяющие входные переменные по две:  $y_1 = f_{11}(x_1, x_2)$ ,  $y_2 = f_{12}(x_1, x_3)$ , ...,  $y_s = f_{1s}(x_{n-1}, x_n)$ . Из них выбирается ограниченный набор частных описаний  $F_1$  наиболее удовлетворяющих внешнему критерию селекции. На втором ряду образуются частные описания второго ряда:  $z_1 = f_{21}(y_1, y_2)$ ,  $z_2 = f_{22}(y_1, y_3)$ , ...,  $z_p = f_{2p}(y_{s-1}, y_s)$ . Из них выбирается  $F_2$  наилучших для использования в следующем, третьем ряду и т. д. Для каждого ряда находится наилучшая (по критерию селекции) модель. Ряды селекции наращиваются, пока оценка критерия уменьшается. Различные варианты многорядного порогового МГУА подробно описаны в [1]. Некоторые варианты МГУА используют различные опорные функции. Широкое распространение получили алгоритмы с ковариациями и с квадратичными частными

описаниями. В этих алгоритмах используются следующие частные описания

$$F(x_1, x_2) = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1^2 + a_4 x_2^2 + a_5 x_1 x_2 \quad (1)$$

$$F(x_1, x_2) = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1 x_2 \quad (2)$$

Хотя существуют МГУА использующие опорные функции более чем двух аргументов (обобщенные МГУА), тем не менее, для синтеза НС (называемых МГУА сети или полиномиальные сети) используют опорные функции двух аргументов вида (1) и (2) [7][8]. Возможно, ограничение на число аргументов оправдано в случае использования полиномов, так как сложные полиномиальные модели, при подстройке их параметров под описываемые данные, ведут себя неустойчиво.

Одна из особенностей представленной работы в том, что в качестве опорной функции используются НС с нейронами, вычисляющими сигмоидную функцию. Сигмоидной функцией называется функция, график которой имеет S-образную форму, дающая приблизительно линейный отклик в середине входного диапазона и эффект насыщения на его концах. Этот класс функций более традиционен в реализациях НС, по сравнению с полиномами. В исследованиях использовалась функция

$$F(X, A) = \frac{(X, A)}{c + |(X, A)|} \quad (3)$$

где  $X$ -вектор входных сигналов;  $A$ -вектор весов синапсов;  $c$  – константа, выбираемая из отрезка  $[0.1, 1]$ . Выбор функции (3) определен простотой ее реализации и вычисления. Одним из недостатков полиномов является то, что они быстро уходят в бесконечность вне интервала, на котором заданы значения. Функция (3) лишена этого недостатка. Она гладкая, непрерывная на всем диапазоне переменных  $X$  и  $A$ , диапазон значений всегда ограничен. С ростом значения  $(X, A)$  функция (3) будет асимптотически стремиться к 1, с уменьшением асимптотически стремиться к -1 (рис. 1).

Другой особенностью работы является универсальность полученных результатов. Из МГУА заимствуется только способ генерации частных описаний. Полученные результаты можно использовать в других эволюционных алгоритмах создания НС, использующих операции скрещивания наряду с другими операциями.




Рис. 1 – Пример графика сигмоидной функции

### 3. ЭКСПЕРИМЕНТЫ

Данные для экспериментов были взяты из проекта ELENA являющегося одним из проектов ESPRIT в области фундаментальных исследований (Basic Research ESPRIT project Number 6891). Тесты проводились на следующих задачах: распознавание типов текстур (Texture database); классификация снимков со спутника Landsat (Satimage database); распознавание фонем французского языка (Phoneme database); распознавание типов цветков ириса (Iris database); классификация в случае двух перекрывающихся классов с нелинейной границей, разделяющей классы (Clouds database); классификация в случае двух не перекрывающихся и линейно не разделяемых классов (Concentric database); классификация в случае двух перекрывающихся гауссовых распределений (Gauss\_3D databases). Для синтеза НС использовался нейроимитатор Neurogenesis (РОСПАТЕНТ №2005611168). Он позволяет, с помощью эволюционного поиска [2][5], автоматически оптимизировать структуру НС, уменьшая ошибки обобщения. Синтез НС выполнялся с отключенной опцией использования МГУА. При синтезе НС, наряду с другими методами (кроме МГУА), использовалось объединение сетей в коллективы. Задачи классификации с учителем формулировались как задачи аппроксимации с заданной точностью. Например, если задано три класса, то классам присваивались соответственно номера 0, 1, 2. Ошибка определялась как разница выхода сети и номера класса. Это не самая эффективная методика решения задачи классификации с учителем, но в данном случае она приемлема, так как целью работы является оценка эффекта от использования МГУА. Для всех задач размер популяции эволюционного алгоритма составлял 100 вариантов структур НС.

МГУА оценивался по результатам тестирования частных описаний второго ряда селекции. Для каждой тестовой задачи

синтезировались две сети N1 и N2. В силу использования в Neurogenesis методов случайной оптимизации, сети имели различную структуру и параметры. Затем каждый пример дополнялся двумя полями. Первое поле заполнялось значением выхода сети N1 на данном примере. Второе поле заполнялось значением выхода сети N2 на данном примере. Далее синтезировались две сети N3 и N4. На вход сети N3 подавались только сигналы от сетей N1 и N2 (рис. 2). На вход сети N4 подавались все поля расширенных примеров (рис. 3).




Рис. 2 – Структура частного описания второго ряда селекции моделируемого сетью N3




Рис. 3 – Структура частного описания второго ряда селекции моделируемого сетью N4

Синтез сетей N3 и N4 моделирует создание частных описаний второго ряда селекции МГУА. Сеть N3 моделирует МГУА, использующий входные переменные только на первом ряду селекции. Сеть N4 моделирует МГУА, использующий входные переменные на каждом ряду селекции. Все сети синтезировались с одинаковыми настройками алгоритма обучения и оптимизации структуры. Исходные постановки

тестовых задач усложнялись (сокращалось число обучающих примеров), так чтобы сети N1 и N2 не достигали высокой точности классификации. В противном случае не удалось бы оценить эффект от МГУА. Параметры задач синтеза НС приведены в таблице 1. В колонке  $\sigma$  указана требуемая точность выхода сетей. В колонке S указано количество синапсов в НС стартовой популяции.

**Таблица 1 – Параметры задач синтеза нейронных сетей**

Задача	Кол-во обучающих примеров	Кол-во тестовых примеров	$\sigma$	S
Texture	1000	4000	0.1	100
Satimage	1000	5000	0.49	100
Phoneme	1000	4000	0.49	50
Iris	100	50	0.1	10
Clouds	1000	4000	0.49	10
Concentric	50	2450	0.49	10
Gauss 3D	100	4900	0.49	10

Также в ходе исследований выяснялось, как влияет структура нейронных сетей N3 и N4 на ошибку тестирования. N3 и N4 строились как слоистые сети [4]. Слоистые сети характеризуются количеством слоев и числом нейронов в каждом слое. Хотя Neurogenesis и позволяет автоматически подбирать наиболее подходящую структуру НС, в целях исследования были наложены ограничения на просматриваемые в ходе эволюции варианты структур. В таблице 2 представлены протестированные варианты структур слоистых сетей.

**Таблица 2 – Варианты структур сетей моделирующих частные описания второго ряда селекции**

№ варианта структуры	Кол-во слоев	Кол-во нейронов в слое
1	1	2
2	1	3
3	1	4
4	2	2
5	2	3
6	2	4
7	3	2
8	3	3
9	3	4

Результаты тестирования сетей N1 и N2 приведены в таблице 3.

**Таблица 3 – Результаты тестирования нейронных сетей N1 и N2 моделирующих частные описания первого ряда селекции**

Задача	Процент верно решенных тестовых примеров	
	N1	N2
Texture	69.18%	77.60%
Satimage	33.94%	31.32%
Phoneme	77.18%	81.34%
Iris	78.00%	64.00%
Clouds	85.90%	84.60%
Concentric	95.96%	96.49%
Gauss 3D	71.24%	71.26%

Результаты тестирования сетей N3 и N4 с различной структурой приведены в таблицах с 4 по 12.

**Таблица 4 – Результаты тестирования нейронных сетей со структурой № 1**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.12%	78.89%
Satimage	34.32%	33.98%
Phoneme	81.57%	82.21%
Iris	79.00%	78.77%
Clouds	86.31%	86.52%
Concentric	97.72%	97.04%
Gauss 3D	72.27%	72.00%

**Таблица 5 – Результаты тестирования нейронных сетей со структурой № 2**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.49%	78.97%
Satimage	35.09%	34.04%
Phoneme	82.07%	82.78%
Iris	79.65%	78.90%
Clouds	87.23%	87.12%
Concentric	97.75%	97.54%
Gauss 3D	72.17%	72.24%

**Таблица 6 – Результаты тестирования нейронных сетей со структурой № 3**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.13%	78.67 %
Satimage	34.49%	34.00%
Phoneme	81.57%	82.21%
Iris	79.33%	78.86%
Clouds	87.65%	87.05%
Concentric	97.20%	97.07%
Gauss 3D	73.78%	73.21%

**Таблица 10 – Результаты тестирования нейронных сетей со структурой № 7**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	81.14%	85.56%
Satimage	49.07%	34.23%
Phoneme	82.04%	81.21%
Iris	91.33%	77.69%
Clouds	87.40%	86.33%
Concentric	98.34%	98.02%
Gauss 3D	74.00%	74.32%

**Таблица 7 – Результаты тестирования нейронных сетей со структурой № 4**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.20%	78.13 %
Satimage	35.62%	34.23%
Phoneme	81.67%	82.75%
Iris	79.61%	79.00%
Clouds	86.23%	86.37%
Concentric	98.04%	97.57%
Gauss 3D	73.23%	73.22%

**Таблица 11 – Результаты тестирования нейронных сетей со структурой № 8**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	81.49%	85.90%
Satimage	49.14%	34.46%
Phoneme	82.77%	81.50%
Iris	91.33%	78.00%
Clouds	87.47%	86.57%
Concentric	99.22%	99.10%
Gauss 3D	75.22%	74.16%

**Таблица 8 – Результаты тестирования нейронных сетей со структурой № 5**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.02%	78.23 %
Satimage	35.54%	33.96%
Phoneme	81.68%	82.89%
Iris	79.46%	79.03%
Clouds	86.98%	86.35%
Concentric	98.03%	97.64%
Gauss 3D	73.08%	73.23%


**Таблица 12 – Результаты тестирования нейронных сетей со структурой № 9**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	81.03%	85.11%
Satimage	49.10%	34.32%
Phoneme	81.23%	81.51%
Iris	90.99%	77.89%
Clouds	87.30%	86.11%
Concentric	98.78%	98.81%
Gauss 3D	75.12%	74.05%


**Таблица 9 – Результаты тестирования нейронных сетей со структурой № 6**

Задача	Процент верно решенных тестовых примеров	
	N3	N4
Texture	78.00%	78.03 %
Satimage	35.13%	33.36%
Phoneme	81.56%	82.43%
Iris	79.20%	79.13%
Clouds	86.97%	86.31%
Concentric	97.78%	97.56%
Gauss 3D	73.02%	72.45%

Средний процент верных ответов по всем задачам для сетей N3 и N4 в зависимости от выбранной структуры приведен на рис. 4 и 5.



**Рис. 4 – Зависимость среднего процента правильно решенных тестовых примеров в зависимости от выбранной структуры сети N3**



**Рис. 5 – Зависимость среднего процента правильно решенных тестовых примеров в зависимости от выбранной структуры сети N4**

Анализ результатов тестирования показывает, что наиболее предпочтительной является структура с тремя слоями и тремя нейронами в каждом слое как для сети N3, так и для сети N4. Именно эту структуру можно рекомендовать в качестве начального варианта опорной функции. Дальнейшая эволюция структур приведет к наиболее подходящей структуре для конкретной задачи.

#### 4. ВЫВОДЫ


Проведенные эксперименты показывают повышение точности нейронных сетей при применении МГУА. В среднем, наибольшая эффективность наблюдается при применении МГУА использующего входные переменные только на первом ряду селекции. Только для задачи распознавания текстур (Texture) наблюдалась большая эффективность МГУА использующего входные переменные на каждом ряду селекции. Несмотря на то, что при генерации частных описаний первого ряда селекции (сети N1 и N2) применялась эволюционная оптимизация структуры сетей и объединение сетей в коллективы, тестирование частных описаний второго ряда селекции (сети N3 и N4) показывало существенный рост точности моделирования. Это говорит об оправданности введения методов объединения сетей по МГУА в процедуру синтеза нейросетевых моделей. В качестве начального варианта опорной функции рекомендуется брать трехслойную сеть с тремя нейронами в каждом слое.

#### 5. СПИСОК ЛИТЕРАТУРЫ

- [1] Индуктивный метод самоорганизации сложных систем / Ивахненко А.Г.-Киев: Наук. думка, 1981-296 с.
- [2] Метод эволюционной оптимизации и его приложение к задаче синтеза искусственных нейронных сетей / Хомич А.В., Жуков Л.А. //

Нейрокомпьютеры: разработка, применение.- 2004. - № 12. - С. 3-15.

- [3] Гилев С.Е. Обучение нейронных сетей: Методы, алгоритмы, тестовые испытания, примеры приложения: Дисс. канд. физ.-мат. наук. Красноярск, 1997.-187с.
- [4] Горбань А.Н. Обучение нейронных сетей. М.: изд. СССР-США СП "ParaGraph", 1990.-160с.
- [5] Хомич А.В., Жуков Л.А. Оптимизация топологии рекуррентных и многослойных нейронных сетей с применением генетических алгоритмов // Нейроинформатика-2004. Сборник научных трудов. Ч.2. М.: МИФИ, 2004. С.68-74.
- [6] Whitley D. Genetic Algorithms and Neural Networks, Genetic Algorithms in Engineering and Computer Science. pp: 203-216, 1995.
- [7] Hecht-Nielsen R. Neurocomputing. Addison Wesley Publ. Co., 1990, p.433
- [8] Farlow, S.J. (ed.), Self Organizing Methods in Modeling: GMDH Type Algorithms, (Marcel Dekker Inc., New York, 1984), p.350.



**Хомич Андрей Владимирович**  
Выпускник Сибирского Государственного Технологического Университета (СибГТУ) 2001 года с дипломом инженера по специальности «программное обеспечение вычислительной техники и автоматизированных систем». С 2003 года аспирант СибГТУ на кафедре «Информационные Технологии». Научный руководитель к.т.н. доцент Жуков Леонид Александрович. Научные интересы лежат в области искусственных нейронных сетей и эволюционных алгоритмов.



**Жуков Леонид Александрович**  
Закончил Красноярский Политехнический Институт в 1986 году. Кандидатскую диссертацию защитил в 2000 году. Работает преподавателем на кафедре ИТ Сибирского Государственного Технологического Университета (СибГТУ) и на кафедре Систем Искусственного Интеллекта Красноярского Государственного Технического Университета. Научные интересы лежат в области искусственных нейронных сетей и их приложений для решения задач лингвистики, образования и других. С 1997 года по настоящее время проводит на базе СибГТУ ежегодную зимнюю школу по нейроинформатике.

# APPLICATION OF THE GROUP METHOD OF DATA HANDLING IN SYNTHESIS OF SUPRVIDED NEURAL NETWORKS

Homich Andrew Vladimirovich <sup>1)</sup>, Zhukov Leonid Alexandrovich <sup>2)</sup>

<sup>1)</sup> The post-graduate student, 660049, Russia, Krasnoyarsk, prospectus of the World 82, Siberian state university of technology, supremum76@rambler.ru

<sup>2)</sup> The senior lecturer, Russia, Krasnoyarsk, prospectus of the World 82, Siberian state university of technology, zhukov\_l@rambler.ru, http://zhukov.wallst.ru

**Abstract:** *The expediency of application of group method of data handling (GMDH) in synthesis supervised artificial neural networks is considered. Comparison of efficiency of two variants GMDH is carried out. Methods using entrance variables on everyone and only the first line of selection are considered. Efficiency of offered methods is estimated experimentally on practical problems.*

**Key words:** *Artificial neural network, Evolutionary algorithms, GMDH.*

## 1. INTRODUCTION

There are practically important problems in which application of neurocomputing methods demands use of networks containing hundreds or more neurons. Sometimes the available the data volume is insufficient for qualitative training networks by existing methods. Sometimes both factors are present simultaneously. It results in a high mistake of generalization [3][4]. The requirement to volume and data quality essentially depends on the chosen of connection between neurons. There are researches in which are used evolutionary search methods for neural networks synthesis [6][2][5]. Evolutionary algorithms demand the big computing expenses. Therefore there is actual a problem of effective evolutionary search and it adaptation to a neural networks synthesis. It is necessary to use crossing operations allowing effectively uniting "experience" of two or more neural networks. The group method of data handling [1] is evolutionary algorithm. *GMDH* it was used for synthesis of neural networks [7][8]. In these researches were used networks with polynomial functions of activation neurons (high order perceptron). Neurons calculate a polynom from two variables in such networks. In given article are offered synthesis neural networks methods using neurons with sigma-function. Restrictions are not imposed on amount of input signals in neuron.

## 2. SYNTHESIS OF NEURAL NETWORKS WITH SIGMA-FUNCTION OF ACTIVATION NEURONS

Multi-line threshold *GMDH* [1] receives some vector of entrance variables  $x=x_1, x_2, \dots, x_n$  on an input. «Individual descriptions» uniting entrance variables are formed in pairs on the first line of

selection:  $y_1=f_{11}(x_1, x_2), y_2=f_{12}(x_1, x_3), \dots, y_s=f_{1s}(x_{n-1}, x_n)$ . Limited set of individual descriptions  $F_1$  get out of the satisfying external criterion of selection from them. Individual descriptions of the second lines are formed on the second line:  $z_1=f_{21}(y_1, y_2), z_2=f_{22}(y_1, y_3), \dots, z_p=f_{2p}(y_{s-1}, y_s)$ . The best individual descriptions get out  $F_2$  from  $F_1$  for use in the following, the third line, etc. Best (by criterion of selection) model gets out for each lines. Lines of selection are increased, while the rating of criterion decreases. Various variants multi-line threshold *GMDH* are in detail described in [1]. Algorithms with covariations and with square-law individual descriptions are popular. The following individual descriptions are used in these algorithms

$$F(x_1, x_2) = a_0 + a_1x_1 + a_2x_2 + a_3x_1^2 + a_4x_2^2 + a_5x_1x_2 \quad (1)$$

$$F(x_1, x_2) = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 \quad (2)$$

Though exist *GMDH* using basic functions more than two arguments (generalized *GMDH*), nevertheless, for synthesis of neural networks (named *GMDH* networks or polynomial networks) use basic functions of two arguments (1) and (2) [7][8]. Complex polynomial models behave unstably at tuning their parameters under the data. It is offered to use neural networks with neurons, calculating sigma-function, as basic functions

$$F(X, A) = \frac{(X, A)}{c + |(X, A)|} \quad (3)$$

Where a X-vector of input signals; a A-vector of weights synapses; c - a constant chosen from a range

[0.1,1]. One of lacks of polynoms is that they quickly leave in infinity outside of an interval on which values arguments are set. Function (3) is deprived this lack. Function (3) aspire to 1 with growth of value  $(X, A)$ , with reduction to aspire to  $-1$  (fig. 1).




Fig. 1 – Example of the sigma-functions

### 3. EXPERIMENTS

The data for experiments have been taken from project ELENA being by one of projects ESPRIT in the field of basic researches (Basic Research ESPRIT project Number 6891). Texture database, satimage database, phoneme database, iris database, clouds database, concentric database and gauss\_3D databases were used for testing. Neurosimulator “Neurogenesis” was used for synthesis of neural networks. It allows, with the help of evolutionary search [2][5], automatically to optimize structure of a neural network. The mistake of generalization is used as criterion of optimality. Synthesis of neural networks was carried out with the switched - off option of use *GMDH*. The size of a population of evolutionary search made 100 variants of structures of neural networks for all tasks.

*GMDH* was estimated by results of testing individual descriptions of the second lines of selection. Two networks N1 and N2 were synthesized for each test task. Further each example was supplemented with two fields. The first field was filled by value of an output of network N1 on the given example. The second field was filled by value of an output of network N2 on the given example. Further two networks N3 and N4 were synthesized. On an input of network N3 signals from networks N1 and N2 moved only. On an input of network N4 all fields of the expanded examples moved. Synthesis of networks N3 and N4 models creation of individual descriptions of the following lines of selection *GMDH*. Network N3 models *GMDH*, using input variables only on the first line of selection. Network N4 models *GMDH*, using input variables on each line of selection. All networks were synthesized with identical algorithm

settings of training and structure optimization. Parameters neural networks synthesis tasks are shown in table 1. Required precision of an output of networks is specified in column  $\sigma$ . Amount of synapses are specified in neural networks of a starting population shown in column S. Results of experiments are shown in table 2.

Table 1 – Parameters of neural networks synthesis tasks

Tasks	Amount of training samples	Amount of test samples	$\sigma$	S
Texture	1000	4000	0.1	100
Satimage	1000	5000	0.49	100
Phoneme	1000	4000	0.49	50
Iris	100	50	0.1	10
Clouds	1000	4000	0.49	10
Concentric	50	2450	0.49	10
Gauss 3D	100	4900	0.49	10

Table 2 – Results of neural networks testing

Tasks	Percent of correct solved test examples			
	N1	N2	N3	N4
Texture	69.18%	77.60%	81.49%	85.90%
Satimage	33.94%	31.32%	49.14%	34.46%
Phoneme	77.18%	81.34%	82.77%	81.50%
Iris	78.00%	64.00%	91.33%	78.00%
Clouds	85.90%	84.60%	87.47%	86.57%
Concentric	95.96%	96.49%	99.22%	99.10%
Gauss 3D	71.24%	71.26%	75.22%	74.16%

### 4. CONCLUSION

Experiments show increase of accuracy of neural networks at application *GMDH*. On the mean, the greatest efficiency is observed at application *GMDH* using entrance variables only on the first line of selection.

### 5. REFERENCES

- [1] Inductive method of self-organizing of complex systems / Ivahnenko A.G.-Kiev: Sciences idea, 1981-296 p.
- [2] Method of evolutionary optimization and its application to a problem of synthesis of artificial neural networks / Homich A.V., Zhukov L.A. // Neurocomputers: designing, application.-2004.-№ 12.-pp. 3-15.
- [3] Gilev S.E. Training of neural networks: Methods, algorithms, test tests, examples of the application: the Dissertation of the candidate of physical and mathematical sciences. Krasnoyarsk, 1997.-187 p.



- [4] Gorban A.N. Training of neural networks. M.: publishing house the USSR - USA of joint venture " ParaGraph ", 1990.-160 p.
- [5] Homich A.V., Zhukov L.A. Recurrent and multilayered neural networks optimization of topology with application of genetic algorithms //Neuroinformatic-2004. The collection of proceedings. P.2. M.: MEPhI, 2004. pp. 68-74.
- [6] Whitley D. Genetic Algorithms and Neural Networks, Genetic Algorithms in Engineering and Computer Science. pp: 203-216, 1995.
- [7] Hecht-Nielsen R. Neurocomputing. Addison Wesley Publ. Co., 1990, p.433
- [8] Farlow, S.J. (ed.), Self Organizing Methods in Modeling: GMDH Type Algorithms, (Marcel Dekker Inc., New York, 1984), p.350.