

*На правах рукописи*



Хандаров Фёдор Владимирович

**МЕТОД ОДНОВРЕМЕННОГО  
СТРУКТУРНО-ПАРАМЕТРИЧЕСКОГО СИНТЕЗА  
МНОГОСЛОЙНЫХ ПЕРСЕПТРОНОВ**

05.13.18 – Математическое моделирование, численные методы  
и комплексы программ

**АВТОРЕФЕРАТ**

диссертации на соискание ученой степени  
кандидата технических наук

Улан-Удэ – 2014

Работа выполнена в Институте математики и информатики  
ФГБОУ ВПО «Бурятский государственный университет»

**Научный  
руководитель**

— Дармаев Тумэн Гомбоцыренович,  
кандидат физико-математических наук,  
доцент кафедры прикладной математики  
ФГБОУ ВПО «Бурятский государственный уни-  
верситет»

**Официальные  
оппоненты**

— Носков Сергей Иванович,  
доктор технических наук, профессор,  
руководитель научно-образовательной лаборато-  
рии моделирования сложных систем  
ФГБОУ ВПО «Иркутский государственный уни-  
верситет путей сообщения»

— Хаптахаяева Наталья Баясхалановна,  
кандидат технических наук, доцент  
кафедры «Системы информатики»  
ФГБОУ ВПО «Восточно-Сибирский государ-  
ственный университет технологий и управления»

**Ведущая  
организация**

— ФГБУН «Институт динамики систем  
и теории управления» СО РАН

Защита диссертации состоится «23» октября 2014 года в 15:30 часов на заседании Диссертационного совета Д 212.022.10 при ФГБОУ ВПО «Бурятский государственный университет» по адресу: 670000, Республика Бурятия, г. Улан-Удэ, ул. Смолина, 24а.

С диссертацией можно ознакомиться в научной библиотеке ФГБОУ ВПО «Бурятский государственный университет», по адресу г. Улан-Удэ, ул. Ранжурова, 4а, а также на сайте <http://www.bsu.ru/?mod=disser>.

Автореферат разослан «\_\_\_» \_\_\_\_\_ года.

Ученый секретарь диссертационного совета  
212.022.10, к.ф.-м.н., доцент



Т. Г. Дармаев

## ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

**Актуальность и степень разработанности темы.** Для построения математических моделей на основе эмпирической информации (по данным наблюдений над объектом) распространенным подходом является использование *искусственных нейронных сетей (ИНС)*. Одним из наиболее исследованных классов ИНС являются *многослойные персептроны (МП)* – сети с прямым распространением сигнала (от входов к выходам) со слоистой топологией нейронов и сигмоидальными активационными функциями. Математическое обоснование использования МП содержится в теоремах Стоуна-Вейерштрасса, А. Н. Колмогорова и В. И. Арнольда; работах R. Hecht-Nielsen, G. Cybenko, В. Крейновича, А. Н. Горбаня и др.

Работа опирается на исследования А. И. Галушкина, которые показывают, что одной из наиболее структурно простых разновидностей МП является сеть с полными перекрестными связями, т. е. со связями между нейронами одного слоя. При этом отмечается, что для большего снижения размерности можно рассматривать и другие разновидности МП с перекрестными связями, поэтому в работе используются *МП с разомкнутыми перекрестными связями (МППС)*, т. е. МП, в которых связи между нейронами одного слоя могут присутствовать, но не должны образовывать замкнутых контуров.

Процесс моделирования с использованием ИНС сводится к определению топологии сети и к дальнейшему подбору весов ее межнейронных связей, т. е. обучению сети, которое происходит до тех пор, пока отклонение между желаемым и производимым сетью откликами не достигнет требуемого уровня для обучающей выборки. Данная задача является многопараметрической задачей нелинейной оптимизации.

Одним из основных этапов развития концепции ИНС стала разработка метода *обратного распространения ошибки (ОРО)*, позволяющего рассчитывать градиент функции ошибки и используемого в градиентных методах обучения ИНС. Первые упоминания ОРО можно найти в работах А. И. Галушкина и П. Дж. Вербоса. Дальнейшее развитие метод получил в работах С. И. Барцева и В. А. Охонина, А. Н. Горбаня, Д. Руммельхарта, Дж. Е. Хинтона и Р. Дж. Вильямса, Y. LeCun. К обучению ИНС применялись различные методы безусловной оптимизации, в том числе известные алгоритмы BFGS и Левенберга-Марквардта, различные модификации метода сопряженных градиентов и другие. Однако сложность характера (овражность, наличие плато и многоэкстремальность) и высокие затраты на расчет значения целевой функции ошибки обучения и ее производных на больших выборках эмпирических данных делают процедуру обучения ИНС градиентными методами при решении реальных задач весьма трудоемкой.

Вместе с тем в последнее время активно развиваются различные подходы глобального стохастического поиска (эволюционные/генетические алгоритмы, метод имитации отжига, дифференциальная эволюция, поиск с запретами и др.). Вопросы их применения к обучению ИНС занимают такие отечественные и зарубежные ученые, как В. М. Курейчик, В. В. Курейчик, В. Г. Редько, Ю. Р. Цой, D. В. Fogel, L. Ingber, Н.-Р. Schwefel, K. Stanley, X. Yao и др. При этом вычислительно эффективных алгоритмов все еще известно достаточно немного. К тому же, как отмечается авторитетными исследователями теории и практики глобального поиска А. А. Жиглявским и А. Г. Жилинским, «локальные методы оптимизации состав-

ляют важную часть глобальной методологии оптимизации» и «типичная глобальная стратегия оптимизации всегда является компромиссом между двумя конкурирующими целями: глобальностью и локальностью поиска», поэтому полный отказ от локальных методов представляется недостаточно обоснованным, особенно в таких сложных задачах, как обучение нейронных сетей.

Не менее важной задачей, чем подбор оптимального набора весов в фиксированной топологии является собственно определение данной топологии, структурный синтез сети. Изначально подбор структуры осуществлялся исследователем вручную (без применения средств автоматизации), исходя из его субъективного понимания предметной области. Впоследствии А. Н. Горбанем, Е. М. Миркесом, S. E. Fahlman, В. Hassibi, Y. LeCun и др. предложены различные конструктивные и деструктивные методы подбора топологии, применяемые после процедуры настройки весов.

В последние годы настройку весов связей и подбор топологии производят в некотором смысле одновременно: пространство поиска охватывает топологически различные сети. В данном случае речь идет скорее о стратегиях переключения между различными топологиями. Особенно часто такой подход применяется в различного рода мультистартовых методах. Заметим, что при этом существующие методы все еще не обеспечивают получение топологий малых размеров, наиболее выгодных на практике.

Резюмируя сказанное выше, можно утверждать, что перспективными направлениями исследований в области нейросетевого моделирования являются:

- 1) поиск способов вычислительно эффективного комбинирования локальных и глобальных алгоритмов при обучении ИНС и, в частности, МПРПС;
- 2) решение проблемы подбора оптимальной топологии сетей путем спецификации структуры непосредственно в процессе обучения.

Таким образом, **актуальность работы** следует из необходимости разработки новых методов обучения МПРПС, использующих комбинацию подходов глобального стохастического поиска и градиентных методов и позволяющих эффективно осуществлять спецификацию топологии сетей во время идентификации параметров, т. е. производить одновременный структурно-параметрический синтез сетей.

**Целью** работы является разработка метода структурно-параметрического синтеза МПРПС на основе подходов глобального случайного поиска и адаптации топологии в процессе обучения.

Для достижения поставленной цели были решены следующие **задачи**:

- 1) сформулировать постановку задачи структурно-параметрического синтеза МПРПС и предложить схему ее решения;
- 2) разработать на основе предложенной схемы вычислительно эффективные метод и алгоритмы структурно-параметрического синтеза МПРПС;
- 3) реализовать разработанные метод и алгоритмы в виде комплекса программ;
- 4) провести апробацию алгоритмов и программного обеспечения на представительных тестовых и прикладных задачах.

**Методы исследования:** анализ и обобщение результатов ранее проведенных исследований в области искусственных нейронных сетей; применение методов теории оптимизации, теории вероятностей, математической статистики, машинного обуче-

ния; исследование эффективности разработанных алгоритмов с помощью вычислительных экспериментов.

Работа **соответствует паспорту** специальности 05.13.18 «Математическое моделирование, численные методы и комплексы программ» по пунктам 1 (разработан новый метод структурно-параметрического синтеза нейросетевых моделей), 3 (разработан новый алгоритм глобального поиска), 4 (разработан комплекс программ нейросетевого моделирования), 5 (исследованы проблемы прогнозирования из областей экономики и образования – получены модели прогнозирования налоговых поступлений и результатов ЕГЭ).

**Научную новизну** результатов работы составляют:

- 1) разработана новая мультистартовая схема одновременного подбора топологии и настройки весов связей МПРПС, в которой для каждой сети реализуется собственная поисковая стратегия; на основе данной схемы разработан новый метод структурно-параметрического синтеза МПРПС;
- 2) разработан новый алгоритм глобального поиска, используемый в работе в качестве способа нелокального параметрического улучшения МПРПС;
- 3) предложена новая стратегия модификации топологии МПРПС для мультистартовых методов.

**Теоретическая и практическая значимость результатов работы.** Разработанные метод и алгоритмы определяют перспективное направление развития в области разработки эффективных методов нейросетевого моделирования.

Разработанные метод и алгоритмы и их программная реализация использовались для выполнения работ в рамках грантов РГНФ и Бурятского государственного университета. Комплекс используется в работе Института математики и информатики Бурятского государственного университета, Управления довузовской подготовки Бурятского государственного университета, Отдела прогнозирования рынка труда Министерства экономики Республики Бурятия, а также в исследованиях Отдела региональных экономических исследований БНЦ СО РАН.

**Степень достоверности и апробация результатов.** Достоверность результатов диссертации обусловлена использованием апробированных научных методов и средств, разработанных авторитетными специалистами: А. И. Галушкиным, А. Н. Горбанем, А. А. Жиглявским, А. Г. Жилинским, Р. Шнабелем, Y. LeCun и др., сопоставлением с результатами расчетов других авторов, проведением вычислительных экспериментов.

Результаты работы обсуждались на Всероссийских семинарах «Нейроинформатика, ее приложения и анализ данных» (Красноярск, 2008, 2009); в школе-семинаре молодых ученых «Математическое моделирование и информационные технологии: управление, искусственный интеллект и технологии программирования» (Улан-Удэ – оз. Байкал, 2006); на Международных конференциях «Инфокоммуникационные и вычислительные технологии и системы» (Улан-Удэ – оз. Байкал, 2009, 2010), «Математика, её приложения и математическое образование» (Улан-Удэ – оз. Байкал, 2009); на семинарах Института математики и информатики БГУ, Отдела региональных экономических проблем БНЦ СО РАН, Института динамики систем и теории управления СО РАН.

Работа по теме диссертации была отмечена II премией на I региональном конкурсе среди молодых ученых Республики Бурятия «Конкурентоспособность региона в условиях экологических и демографических ограничений» (ОРЭИ БНЦ СО РАН, Улан-Удэ, 2009).

**Публикации и личный вклад автора.** По теме диссертации опубликовано 8 работ, 3 из которых опубликованы в журналах из перечня ВАК РФ.

Результаты Главы 1 опубликованы в работах [1, 5]; Главы 2 – в [1; 3-5]; главы 3 – в [3-5, 6-8]. Все результаты, выносимые на защиту, получены автором лично. В работах [1-8] постановка задачи, подготовка данных, разработка и апробация алгоритмов выполнены автором лично. В работах [1, 3] сравнительный анализ разработанных алгоритмов и существующих методов произведен автором совместно с научным руководителем, Дармаевым Т.Г.; в работах [2; 6-8] экономическая трактовка полученных результатов выполнена автором совместно с Дондоковым З. Б.-Д.; в работе [4] подготовка данных и экономическая трактовка полученных результатов выполнена автором совместно с Дондоковым З. Б.-Д. и Каницкой А. Л.; в работах [4-5] постановка задачи, разработка алгоритмов выполнены автором лично, программная реализация выполнена в неделимом соавторстве со Скворцовым М. В.

**Структура работы.** Диссертация состоит из введения, трех глав, заключения, трех приложений и списка литературы. Общий объем работы составляет 132 страницы. Список литературы содержит 155 наименований, из них 101 – на иностранных языках. В Приложении А приводятся примеры описаний нейросетевых моделей для тестовых задач, решаемых в Главе 2. В Приложении Б – опросник профессиональной готовности, использованный при решении практической задачи в Главе 3. В Приложении В – описание лучшей сети для задачи, решаемой в Главе 3.

## ОБЩЕЕ СОДЕРЖАНИЕ РАБОТЫ

Во **Введении** обосновывается актуальность исследования, ставятся цель и задачи работы, обсуждаются новизна, ее теоретическая и практическая значимость, достоверность и апробация полученных результатов, кратко приводятся основные положения, касающиеся теории искусственных нейронных сетей (ИНС) и, в частности, такой их разновидности, как многослойные персептроны с разомкнутыми перекрестными связями (МПРПС).

В **Главе 1** приводится известная постановка задачи обучения МПРПС с фиксированной топологией. Далее описывается экономный способ представления МПРПС в виде линейных структур, кроме того отличающийся простотой осуществления операций модификации топологии, и приводится постановка задачи обучения нейронных сетей для данного представления, позволяющая переключение между различными топологиями.

Считаем, что имеется выборка примеров (наблюдений), используемых для обучения сети, которую будем называть *обучающим множеством*, и которая может быть представлена в виде  $Teach = \left\{ \left( x^{(t)}, y^{(t)} \right) \right\}_{t=1, \overline{T}}$ , где  $T$  – количество примеров в выборке.

Тогда  $x^{(t)} = \left( x_1^{(t)}, \dots, x_{n_i}^{(t)} \right)$  и  $y^{(t)} = \left( y_1^{(t)}, \dots, y_{n_o}^{(t)} \right)$  – имеющийся  $t$ -й пример наблюдения ( $t \in [1, T]$ ). Матрица смежности графа, соответствующего МПРПС, будет иметь вид

$w \in W = \left\{ (w_{ij}), w_{ij} \in [-w_a, w_a], i, j = \overline{1, n} \right\}$ . Обозначим теперь как  $y_1, \dots, y_{n_i+n_h}$  – выходы входных и скрытых нейронов, тогда отклики сети будут рассчитываться как  $y_j = \varphi \left( \sum_{i=1}^{n_i+n_h} w_{ij} y_i \right)$  при  $j = \overline{n_i + n_h + 1, n_i + n_h + n_o}$ .

Далее в работе показана целесообразность использования гиперболического тангенса в качестве активационной функции. В этом случае при сохранении обозначения  $w \in W$  пространство поиска примет вид  $W = \left\{ (w_i)_{i=1, \overline{L(n_h)}} \mid w_i \in [-w_a, w_a] \right\}$ , где  $L(n_h)$  – длина списка связей, и можно явно выразить зависимость номера позиции веса связи от  $i$ -го нейрона к  $j$ -тому в списке  $w$  для каждого значения  $n_h$ , что при однократной индексации позволит сохранить константный доступ к элементам используемой линейной структуры  $l(i, j, n_h)$  (как и при использовании матрицы смежности):

$$l(i, j, n_h) = \begin{cases} n_o i + j - n_i, & i < n_i, n_i \leq j < n_i + n_o \\ n_i n_o + n_h i + j - n_i - n_o, & i < n_i, n_i + n_o \leq j \\ t + (i - n_o) n_o + j - n_i, & n_i \leq j < n_i + n_o \leq i \\ (2n_h + n_i + n_o - i - 1)(i - n_i - n_o) / 2 + n_i n_o + n_i n_h + n_h n_o + j - i - 1, & n_i + n_o \leq i, j \end{cases}$$

Полностью новая постановка задачи будет выглядеть так:

$$w \in W = \left\{ (w_i)_{i=1, \overline{L(n_h)}} \mid w_i \in [-w_a, w_a] \right\}$$

$$\tilde{y}^{(t)} = \left( \tilde{y}_1^{(t)}, \dots, \tilde{y}_{n_o}^{(t)} \right), \text{ где } y_j = \varphi \left( \sum_{i=1}^{n_i+n_h} w_{l(i, j, n_h)} y_i \right) \text{ при } j = \overline{1, n_o},$$

$$y_k = \begin{cases} \varphi \left( \sum_{i=1}^{k-1} w_{l(i, j, n_h)} y_i \right) & \text{при } k \in [n_i + 1, n_i + n_h] \\ x_k & \text{при } k \in [1, n_i] \end{cases}$$

$$e(w) = \frac{1}{n_o} \frac{1}{T} \sum_{t=1}^T \sum_{k=1}^{n_o} \left( \tilde{y}_k^{(t)} - y_k^{(t)} \right)^2 \rightarrow \min$$

Далее предложена общая популяционная схема структурно-параметрического синтеза МПРПС, основанная на разделении точек на перспективные и неперспективные для градиентного спуска. Согласно принятой схеме далее требуется разработать алгоритм нелокального параметрического улучшения (смена окрестности локального минимума) при сохранении топологии, а также стратегию модификации топологии (см. Рисунок 1 – операции *remove\_conn*, *add\_conn*, *remove\_node*, *add\_node* обозначают соответственно удаление/добавление связи, удаление/добавление нейрона) для применения их к неперспективным точкам. Схема позволяет производить одновременный поиск в пространстве структур и наборов весов связей МПРПС.

**Глава 2** посвящена разработке алгоритма нелокального параметрического улучшения и стратегии модификации топологии.

Особенностями предлагаемой стратегии модификации топологии являются:

1. При усложнении топологии сети полученное решение должно быть явно лучше текущего  $e_t - e_{t+1} > \delta$ , а в случае упрощения – не хуже  $e_t - e_{t+1} \geq 0$ .
2. При успехе модификации топологии заменяется не родительская точка  $w^{(k)}(t+1) = w^{(k)}(t)$ , а худшая точка популяции  $w^{(n)}(t+1) = w^{(k)}(t)$ .
3. Число удаляемых и добавляемых связей всякий раз определяется случайным образом – как равномерно распределенная случайная величина  $\eta_{[0,Q]}$  из интервала  $[0, Q]$ , где  $Q = \varepsilon L_{\max}(n_h)/(n_h + 1)$  при  $\varepsilon \in [0, 1]$ .

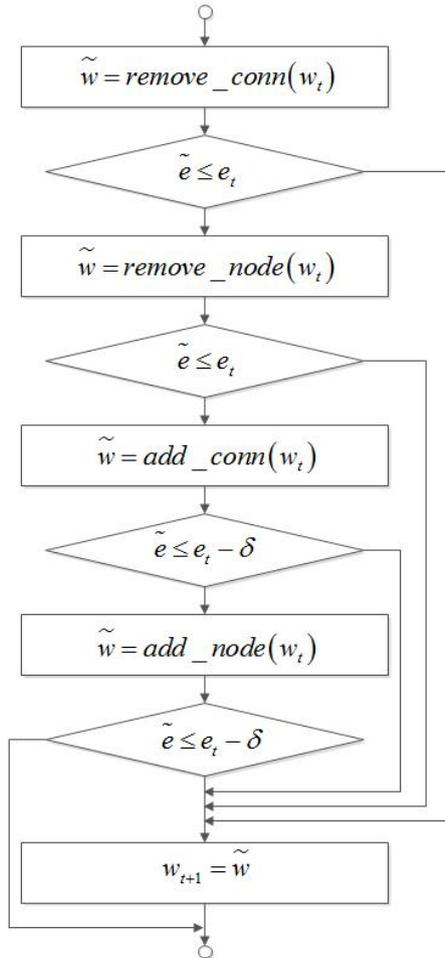


Рисунок 1 – Стратегия модификации топологии

4. Добавление и удаление нейронов производится по одному.

Разработанная стратегия позволяет интенсифицировать «исследование» каждого уровня топологии, вместе с тем снижая диверсификацию. При этом при равной точности соблюдается приоритет простых топологий перед сложными.

Далее в главе описывается разработанный алгоритм нелокального параметрического улучшения, представляющий собой итерационную процедуру глобального стохастического поиска.

Суть ее заключается в следующем: на каждой итерации из текущей точки  $w_t$  получается точка  $w_t$ , являющаяся либо  $w_t^{(ts)}$  – результатом совершения шага по методу поиска с запретами (ts-шаг), либо  $w_t^{(de)}$  – по методу дифференциальной эволюции (de-шаг). Отмечается, что совершение de-шага имеет смысл производить лишь в случаях, когда последовательность ts-шагов привела поиск на дно окрестности локального минимума, показателем чего является либо невозможность формирования *ts-точки*  $w^{(ts)}$ , либо ухудшение значения  $y^{(ts)}$  по сравнению с текущей точкой  $y_t < y^{(ts)}$ .

Общая схема выбора шага и, соответственно, получения точки  $w_t$  приводится на Рисунке 2. Структура списка запретов при таком подходе будет иметь сегментированный вид  $tabu_t = \bigcup_{j=0}^S tabu_{t,j}$  ( $S$  – число сегментов списка запретов), где переход к

каждому новому сегменту будет означать совершение de-шага, а сам сегмент – последовательность точек, полученных произведенными подряд ts-шагами. В качестве точек популяции для совершения de-шага назначаются именно те точки, которые принадлежат различным сегментам списка запретов – по одной от каждого сегмента: случайным и равновероятным образом выбирается три различных номера сег-

ментов  $v_0, v_1, v_2 \in [0, S - 1]$ , в каждом из которых также равновероятно выбирается по одной точке:  $p_j = \text{choise}\{tabu_{t,v_j}\}$  ( $j \in [0, 2]$ ); далее из координат выбранных точек генерируется мутантный вектор  $t = p_0 + \alpha(p_1 - p_2)$ , некоторые координаты которого замещаются координатами точки, выбранной из последнего сегмента списка запретов  $x = \text{choise}_{last}\{tabu_{t,S}\}$ .

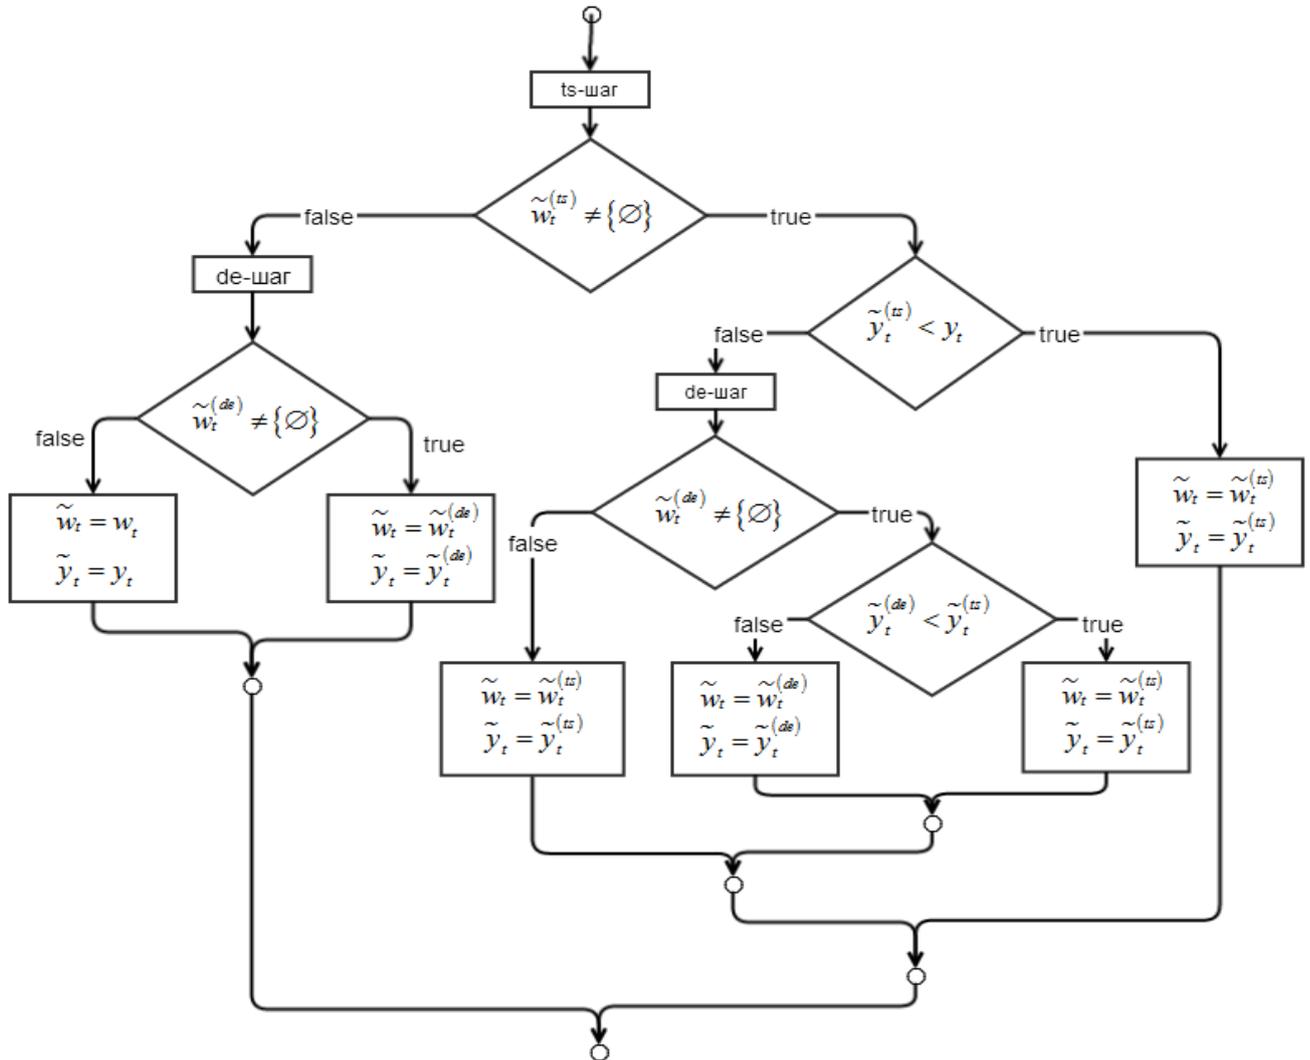


Рисунок 2 – Схема получения пробной точки в разрабатываемом алгоритме

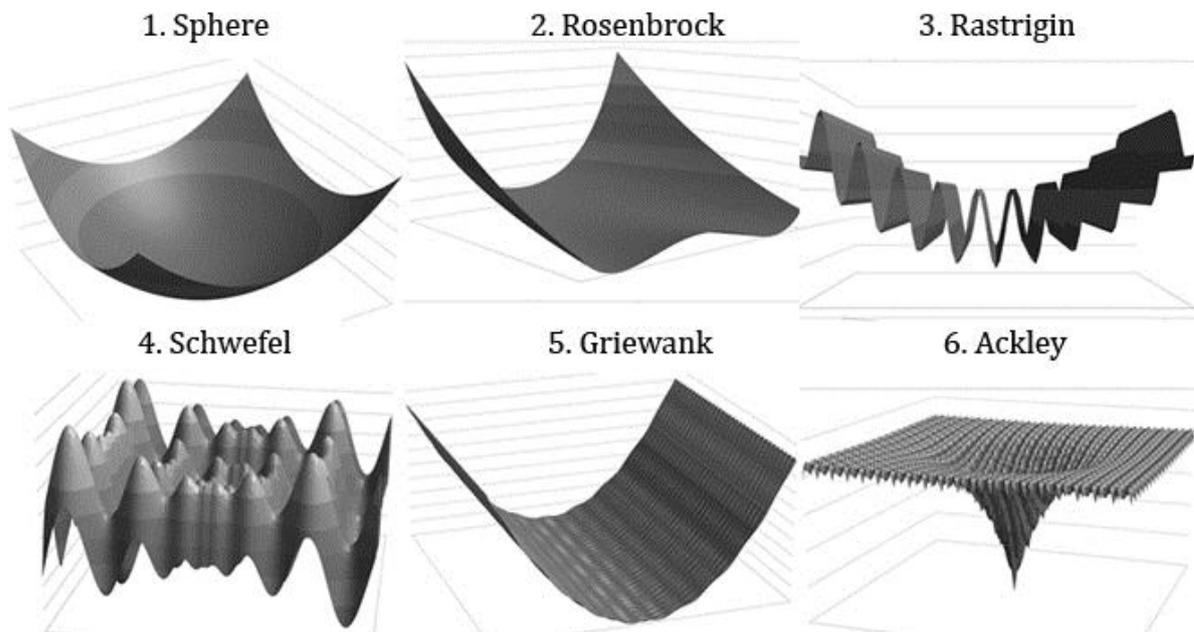
Описанный способ совершения de-шага возможен лишь при  $S \geq 4$  (поскольку нам необходимо не менее 4-х точек и, соответственно, 4-х сегментов), если же  $S < 4$ , то точка начала нового сегмента должна выбираться случайным образом равновероятно по всему пространству поиска за исключением уже запрещенных к этому моменту областей.

Для тестирования алгоритма взят ряд тестовых функций (см. Таблицу 1). Все последующие эксперименты производились при размерности  $N=100$ .

Таблица 1 – Описание тестовых функций

Функция	Область поиска
f1. Sphere: $f(w) = \sum_{i=1}^n w_i^2$	$[-5,12; 5,12]$
f2. Rosenbrock: $f(w) = \sum_{i=1}^{n-1} (100 \cdot (w_{i+1} - w_i^2)^2 + (w_i - 1)^2)$	$[-2,048; 2,048]$
f3. Rastrigin: $f(w) = 10 \cdot n + \sum_{i=1}^n (w_i^2 - 10 \cdot \cos(2\pi w_i))$	$[-5,12; 5,12]$
f4. Schwefel: $f(w) = 418,9829 \cdot n + \sum_{i=1}^n (-w_i \cdot \sin(\sqrt{w_i}))$	$[-500; 500]$
f5. Griewank: $f(w) = 1 + \sum_{i=1}^n \left( \frac{w_i^2}{4000} \right) - \prod_{i=1}^n \cos\left( \frac{w_i}{\sqrt{i}} \right)$	$[-600; 600]$
f6. Ackley: $f(w) = 20 + e - 20 \cdot e^{-0,2 \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n w_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi w_i)}$	$[-30; 30]$

На Рисунке 3 используемые функции изображены при  $N=2$ . Данные изображения позволяют составить представление о характере функций.

Рисунок 3 – Графики тестовых функций (при  $N=2$ )

Для всех функций  $f^* = 0$  и  $w_i^* = 0.0$  (кроме Rastrigin, где  $f^* = 10$ , Rosenbrock, где  $w_i^* = 1.0$ , и Schwefel, где  $w_i^* = 420,9687$ ). Функция Sphere описывает многомерную сферу и является достаточно простой для всех алгоритмов, Rosenbrock имеет большое медленно убывающее плато, все остальные функции являются многоэкстремальными, с различным характером и радиусами локальных минимумов.

Далее в главе описываются результаты вычислительных экспериментов по определению процедур  $choise_{last}$  и  $choise$  и подбору параметра  $\alpha$ . Для процедур  $choise_{last}$  и  $choise$  сравниваются 3 варианта: «посл.» – выбирается последняя точка сегмента (предполагаемое дно исследованной окрестности локального минимума), «перв.» – выбирается первая точка сегмента (одна из наиболее удаленных от предполагаемого локального минимума точек в исследованной окрестности), «случ.» – из сегмента равновероятно выбирается случайная точка. Для параметра  $\alpha$  сравниваются 2 варианта: новое значение  $\alpha$  для каждого нового мутантного вектора («вект.») или для каждой его координаты («коорд.»).

В ячейках Таблицы 2 столбцов «Sphere» ... «Ackley» записаны усредненные по 100 запускам значения функции соответствующего столбца, найденные для набора параметров в соответствующей строке. Лучший набор значений параметров  $choise_{last}$ ,  $choise$  и  $\alpha$  в работе определяется по абсолютному отклонению Err по формуле для  $j$ -той строки  $Err_j = \sum_{k=1}^6 (x_{jk} - \min_k) / (\max_k - \min_k)$ , где  $\min_k$  и  $\max_k$  – минимальное и максимальное значения по  $k$ -тому столбцу,  $x_{jk}$  – значение в  $j$ -той строке.

Таблица 2 – Результаты выбора  $choise_{last}$ ,  $choise$  и значения  $\alpha$  (среднее по 100 запускам)

$choise_{last}$	$choise$	$\alpha$	Sphere	Rosenbrock	Rastrigin	Schwefel	Griewank	Ackley	Err
посл.	посл.	вект.	4,05	354,78	467,37	12954,80	16,75	18,21	0,79
посл.	посл.	коорд.	1,20	247,20	447,85	12788,70	5,51	18,25	0,55
посл.	перв.	вект.	4,56	390,88	458,45	12914,60	18,36	17,90	0,42
посл.	перв.	коорд.	1,60	285,18	467,99	12907,00	6,20	17,80	0,26
посл.	случ.	вект.	4,41	375,59	471,96	12627,60	17,19	18,06	0,61
<b>посл.</b>	<b>случ.</b>	<b>коорд.</b>	<b>1,34</b>	<b>255,69</b>	<b>450,69</b>	<b>12436,40</b>	<b>6,33</b>	<b>17,89</b>	<b>0,12</b>
перв.	посл.	вект.	59,51	1776,66	563,33	16131,70	199,62	18,74	4,53
перв.	посл.	коорд.	48,28	1466,05	551,16	15626,80	164,34	18,36	3,55
перв.	перв.	вект.	89,60	2492,44	593,75	17240,70	316,28	18,45	5,69
перв.	перв.	коорд.	87,32	2410,02	593,44	16667,90	296,29	18,16	5,13
перв.	случ.	вект.	64,35	1885,19	588,83	16329,90	212,06	18,62	4,76
перв.	случ.	коорд.	55,01	1665,89	563,57	15982,80	202,74	18,27	3,91
случ.	посл.	вект.	10,48	563,23	471,75	13393,60	38,68	18,31	1,26
случ.	посл.	коорд.	4,30	416,50	470,64	13154,80	17,02	18,32	1,01
случ.	перв.	вект.	11,63	586,00	488,82	13679,30	45,91	18,19	1,35
случ.	перв.	коорд.	5,07	422,57	453,58	13352,20	20,46	17,95	0,56
случ.	случ.	вект.	9,95	565,05	467,74	13423,60	36,20	18,39	1,31
случ.	случ.	коорд.	4,97	451,66	460,16	13051,20	19,56	18,19	0,81

Из Таблицы 2 видно, что наименьшее значение в столбце Err получено, когда в процедуре  $choise_{last}$  выбирается последняя точка сегмента, в процедуре  $choise$  –

случайная точка сегмента, а  $\alpha$  выбирается равновероятно из  $[-1,1]$  для каждой координаты мутантного вектора. Данный набор параметров используется далее в работе.

Полученный гибридный алгоритм сочетает в себе «исследовательские» способности метода дифференциальной эволюции и скорость сходимости поиска с запретами при спуске к локальному минимуму. Результаты тестирования приводятся на Рисунке 4: на каждом графике по оси абсцисс указано число вызовов целевой функции (ЧВЦФ), по оси ординат – значение в лучшей найденной точке.

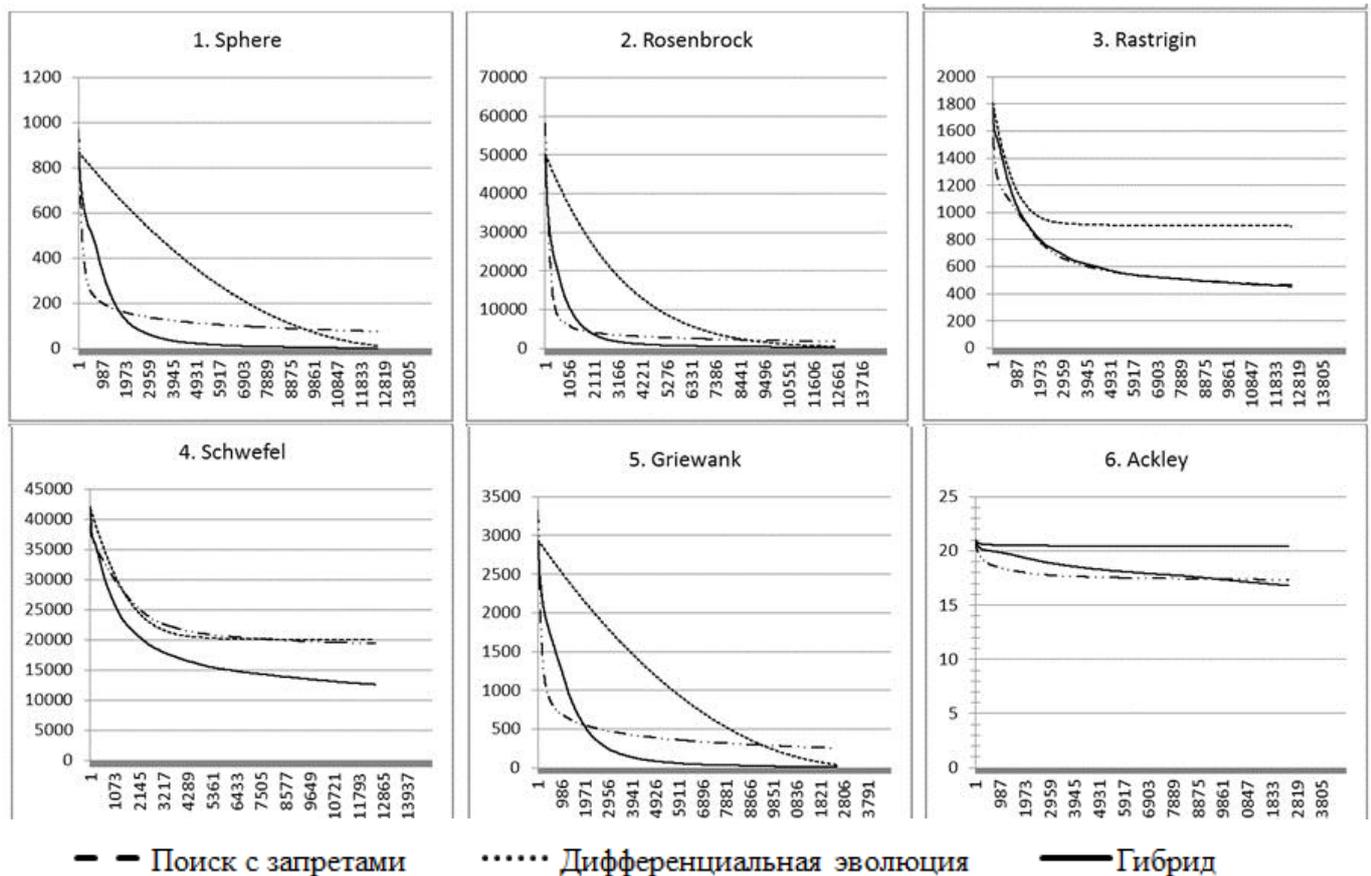


Рисунок 4 – Результаты тестирования алгоритма нелокального улучшения (при  $n=100$ ).

Как видно из Рисунка 4, во всех задачах показано улучшение по сравнению с оригинальными методами поиска с запретами и дифференциальной эволюции, т.е. гибридный метод за одно и то же число вызовов целевой функции находит точку, в которой значение меньше, чем в лучших точках, найденных родительскими методами.

Полученное улучшение объясняется тем, что по окончании спуска на дно окрестности локального минимума (ts-шаг), гибридный метод не тратит время на подъем, а начинает активно «исследовать» пространство поиска (de-шаг).

Далее в Главе 2 приводится полное описание метода СПС (см. Рисунок 5) с новым алгоритмом нелокального параметрического улучшения и стратегией модификации топологии.

Для осуществления квалификации точек в работе выполняется небольшое количество итераций градиентного спуска, которое, как показывает практика, достаточно брать равным 10. Количество итераций градиентного спуска  $i_i^{(k)}$  основного этапа

высчитывается для каждой точки следующим образом: пусть  $\Delta f_i^{(k)} = f(w_i^{(k)}) - f(w_i^{(k-1)})$  – приращение, полученное на этапе предварительного локального спуска в  $k$ -той точке,  $\bar{\Delta f}_i$  – среднее значение по всем приращениям  $\{\Delta f_i^{(k)}\}_{k=1, \dots, n}$ . Тогда положим  $i_i^{(k)} = \lfloor 100 \cdot \Delta f_i^{(k)} / \bar{\Delta f}_i \rfloor$ . Данная оценка позволяет выделять точки наиболее перспективные для осуществления локального спуска при наличии таковых.

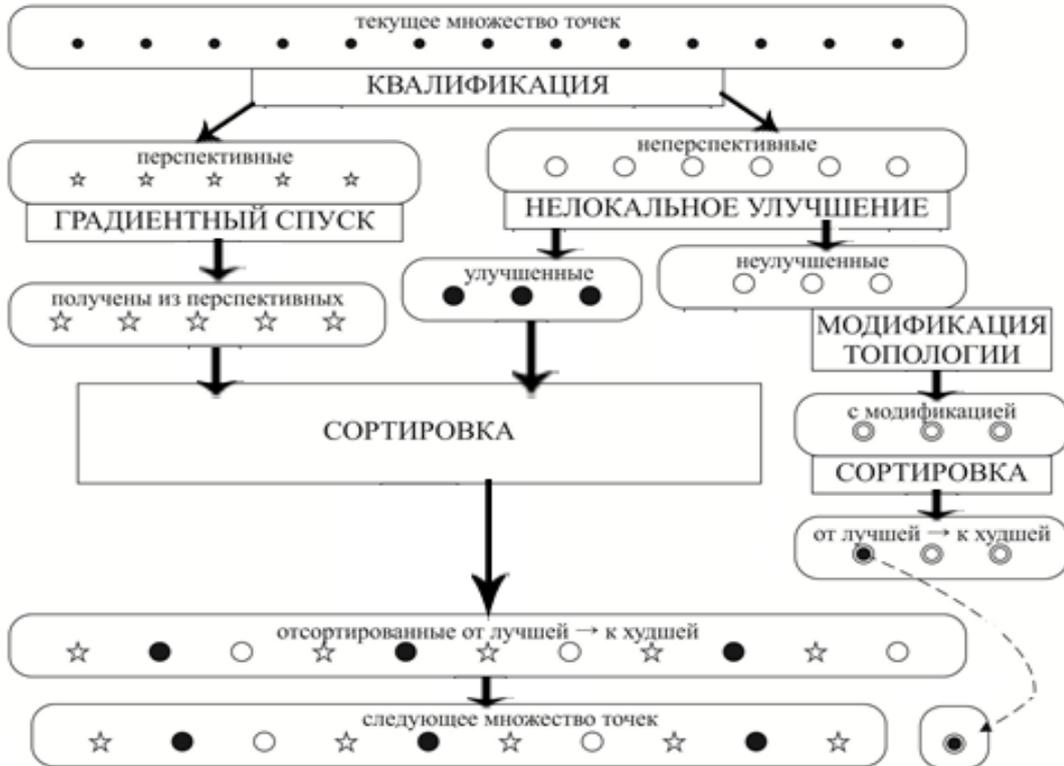


Рисунок 5 – Схема работы с точками популяции в методе СПС

И квалификация, и локальный спуск в работе выполняются одним и тем же градиентным методом, в качестве которого в работе выбран один из известных и широко применяемых квазиньютоновских методов – BFGS (Broyden-Fletcher-Goldfarb-Shanno): как показывают различные источники – наименее затратный в плане числа вызовов целевой функции или градиента. В завершении главы проводится тестирование разработанного метода СПС на ряде задач (Cancer, Glass, Diabetes и HeartAC) из известного сборника задач для тестирования методов обучения ИНС – PROBEN1<sup>1</sup>. Сети, полученные с помощью СПС, сравниваются с эталонными сетями, описанными в PROBEN1 (для обучения использован метод RPROP, топология подбиралась вручную). В Таблице 3 по каждой из задач приводится среднее значе-

<sup>1</sup> Prechelt, L. PROBEN1 – a set of benchmarks and benchmarking rules for neural network training algorithms : technical report no 21/94 / L. Prechelt. – Universitat Karlsruhe, 1994. – 38 p.

ние и стандартное отклонение ошибок обучения и тестирования, числа связей и скрытых узлов для сетей, полученных с помощью СПС (произведено 100 запусков) и описанных в PROBEN1 (60 запусков). Из Таблицы 3 видно, что сети, получаемые при использовании СПС, отличаются меньшей топологической сложностью и лучшей или сопоставимой точностью в сравнении с моделями, полученными ручным подбором топологии.

Таблица 3 – Результаты сравнения сетей (сети, описанные в PROBEN1, обозначены как «P1»).

Название параметра	Значения параметра	Cancer		Glass		Diabetes		HeartAC	
		СПС	P1	СПС	P1	СПС	P1	СПС	P1
Ошибка на тестов. множестве	среднее	2,51	1,60	9,46	9,75	17,52	17,30	3,58	2,82
	ст. откл.	1,13	0,41	0,20	0,41	0,58	1,91	0,88	0,22
Ошибка на обуч. множестве	среднее	3,52	2,87	8,44	7,68	15,75	14,74	4,28	3,86
	ст. откл.	0,21	0,27	0,69	0,79	0,42	2,03	0,28	0,32
Число скрытых нейронов	среднее	2,7	6	2,4	24	1,6	32	3	2
	ст. откл.	1,06	–	0,89	–	0,52	–	0,89	–
Число связей	среднее	30,6	100	73,2	572	25	370	106,2	110
	ст. откл.	2,07	–	15,63	–	4,24	–	25,56	–

Завершающие эксперименты в Главе 2 посвящены исследованию скорости сходимости метода СПС. Сравнивались (см. Рис. 6) следующие операции:

- 1) Подбор весов сетей фиксированной топологии, описанной в PROBEN1;
- 2) Подбор весов сетей фиксированной топологии, предварительно найденной с помощью СПС (время на подбор топологии не учитывалось);
- 3) Подбор и весов, и топологии с помощью СПС.

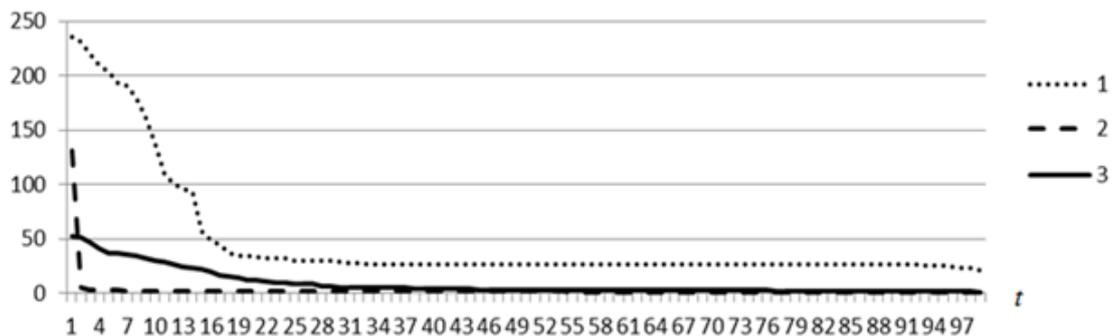


Рисунок 6 – Результаты вычислительных экспериментов по измерению скорости сходимости методов

В первых двух случаях для подбора весов использовался разработанный алгоритм параметрического улучшения. Результаты усреднялись по 100 запускам. Из Рисунка 6 видно, что снижение среднего приращения  $\bar{e}$  в эксперименте 2 происходит значительно быстрее, чем в экспериментах 1 и 3. Хороший старт для эксперимента 3 обусловлен популяционным подходом и небольшой топологией (при первоначальном выборе приближения больше вероятность быстрого попадания в хороший локальный минимум). Плохой старт и медленная настройка для эксперимента 1 объяс-

няются громоздкой топологией и, следовательно, случайным характером подбора хорошего начального решения и трудностью дальнейшего решения задачи оптимизации большей размерности.

Вывод – основное преимущество СПС заключается в решении проблем подбора структуры и выбора метода обучения, при этом в некоторых случаях дополнительно может быть достигнуто значительное ускорение в вычислениях, связанное с топологической простотой синтезируемых моделей.

В **Главе 3** представлен программный комплекс, реализующий метод СПС, и описано его применение для решения задач из области экономики и образования.

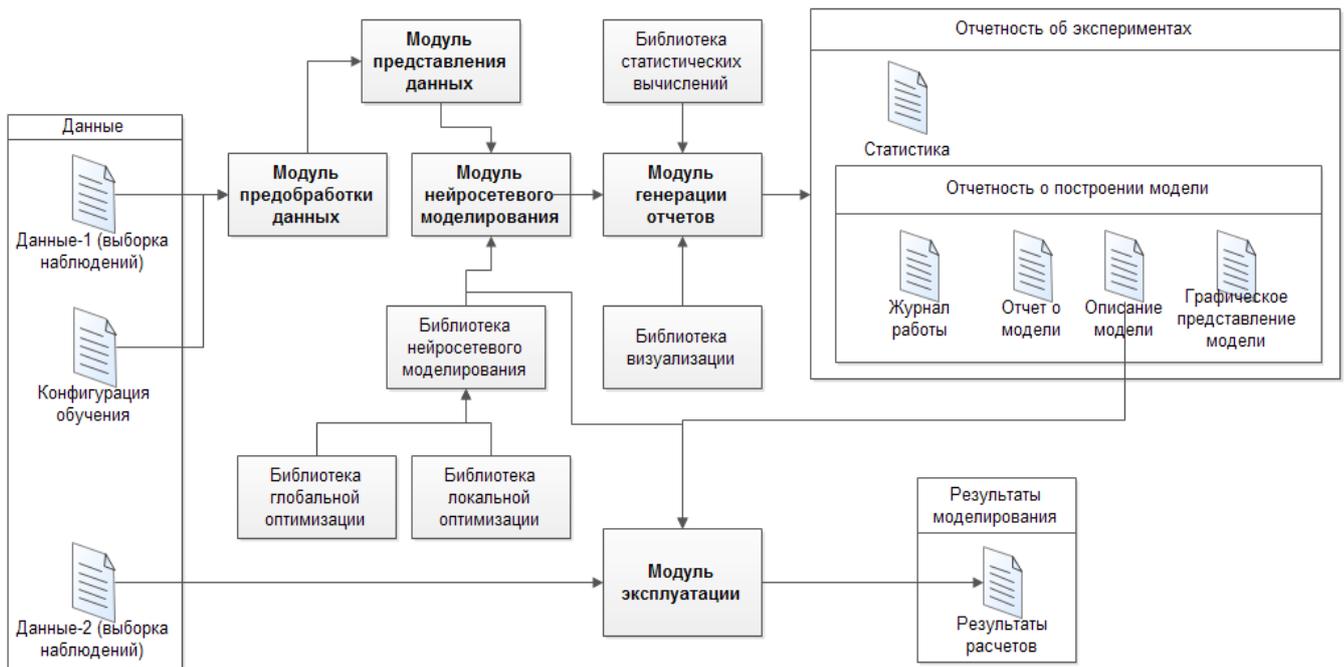


Рисунок 7 – Логическая структура разработанного программного комплекса

Комплекс реализован на языке C++ в виде набора модулей и библиотек классов (см. Рисунок 7) с использованием техники обобщенного программирования (C++ templates), что позволяет значительно улучшить возможности по расширению библиотек алгоритмов, повторному использованию и дальнейшей поддержке программного кода.

Комплекс пригоден для решения задач моделирования по данным наблюдений, допускающих создание нейросетевой модели, при этом качество модели зависит, очевидно, от качества предоставленной выборки эмпирических данных.

Далее в Главе 3 описывается решение прикладных задач нейросетевого моделирования.

Решена экономическая задача прогнозирования налоговых поступлений (на примере Республики Бурятия). На основе данных наблюдений за 60 месяцев требовалось разработать модель краткосрочного прогнозирования в условиях высокой степени неопределенности влияющих факторов, наиболее точно отражающую зависи-

мость любой точки временного ряда от фиксированного числа значений предыдущих наблюдений и опирающуюся лишь на динамику прогнозируемой величины.

Для сравнения было выбрано решение задачи<sup>2</sup>, полученное с помощью более распространенного (при исследовании одномерных временных рядов) подхода, основанного на применении методов АРСС (авто-регрессии проинтегрированного скользящего среднего). Значение средней относительной ошибки модели, полученной методом СПС, составило 10,5125%, что улучшило известный результат на 4,39%. График прогнозирования с помощью СПС изображен на Рисунке 8.

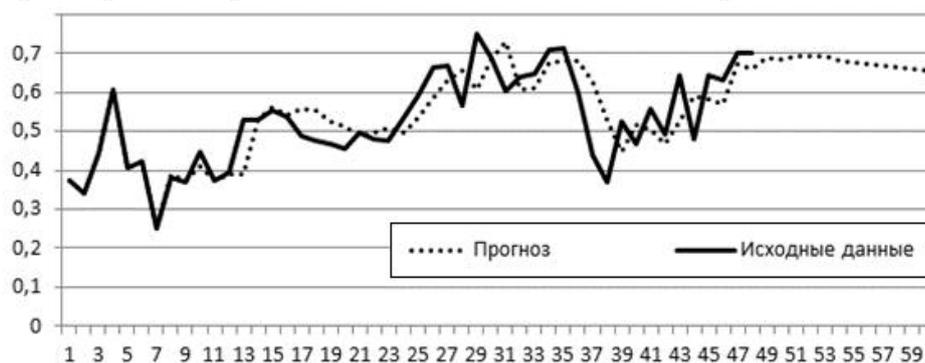


Рисунок 8 – Прогноз с помощью метода СПС

Далее в Главе 3 описывается решение задачи из области менеджмента образования. По 50 входным параметрам, получаемым при прохождении «Опросника профессиональной готовности» Л.Н. Кабардовой<sup>3</sup>, требовалось спрогнозировать результаты сдачи Единого государственного экзамена в баллах. Прогноз, полученный с помощью построенной методом СПС модели, представлен в Таблице 4.

Таблица 4 – Результаты прогнозирования по предметам

Точность прогноза		до 5 баллов				до 10 баллов				до 25 баллов			
из числа:		всех		сдававших		всех		сдававших		всех		сдававших	
Предмет	Экзамен	чел	%	чел	%	чел	%	чел	%	чел	%	чел	%
РУС	418	77	18,42	77	18,42	169	40,43	169	40,43	366	87,56	366	87,56
МАТ	418	71	16,99	71	16,99	137	32,78	137	32,78	302	72,25	302	72,25
ФИЗ	88	330	78,95	0	0	331	79,19	1	1,14	343	82,06	13	14,77
ХИМ	45	373	89,23	0	0	373	89,23	0	0	377	90,19	4	8,89
БИО	80	339	81,10	1	1,25	340	81,34	2	2,50	347	83,01	9	11,25
ИСТ	74	344	82,30	0	0	345	82,54	1	1,35	356	85,17	12	16,22
ГЕО	12	406	97,13	0	0	406	97,13	0	0	406	97,13	0	0
ОБЩ	222	214	51,20	18	8,11	232	55,50	36	16,22	326	77,99	130	58,56
ЛИТ	18	400	95,69	0	0	400	95,69	0	0	400	95,69	0	0
ИНЯ	44	374	89,47	0	0	374	89,47	0	0	376	89,95	2	4,55
ИНФ	30	388	92,82	0	0	388	92,82	0	0	389	93,06	1	3,33

<sup>2</sup> Чимитдоржиева Е.Ц. Доржиева В.В. Влияние мирового кризиса на бюджетную политику субъектов Российской Федерации // Экономический журнал, 2009 №2(16). С. 18-32

<sup>3</sup> Никишина В. Б., Василенко Т. Д. Психодиагностика в системе социальной работы : учеб. пособие для студ. высш. учеб. заведений / М. : Изд-во ВЛАДОС-ПРЕСС, 2004. – 208 с.

Полученные прогнозы свидетельствуют, что нейросетевая модель верно определяет результат с точностью до 25 баллов по любому предмету для 72,25% школьников. Такая точность свидетельствует о хороших возможностях метода СПС при построении сложных нейросетевых моделей.

Изложенная методика прогнозирования пригодна для получения прогноза результатов экзамена (для организации эффективной подготовки); выбора предметов, наиболее благоприятных для успешной сдачи экзамена; выявления работ участников, показывающих неожиданно высокие результаты, для дополнительной проверки.

В **Заключении** сформулированы основные научные результаты и разработки диссертационной работы, выносимые на защиту.

### **ОСНОВНЫЕ НАУЧНЫЕ РЕЗУЛЬТАТЫ И РАЗРАБОТКИ, ВЫНОСИМЫЕ НА ЗАЩИТУ**

1. Мультистартовая схема одновременного подбора топологии и настройки весов связей МПРПС, отличающаяся от известных способом оценки сетей на предмет перспективности применения к ним методов локального спуска, глобального поиска или модификации топологии; метод одновременного структурно-параметрического синтеза, разработанный на основе данной схемы.

2. Новый алгоритм глобального поиска на основе метода поиска с запретами, который отличается от известных ведением сегментированного списка запретов и совершением шага по методу дифференциальной эволюции, эксплуатирующего данную сегментированность.

3. Новая стратегия последовательного выбора операции модификации топологии МПРПС, предназначенная для использования в мультистартовых методах, которая отличается от известных детерминированным порядком выбора операций модификации топологии с приоритетом операций упрощения и нацеленностью на интенсификацию исследования каждого уровня топологии.

4. Программный комплекс для решения задач нейросетевого моделирования, реализующий предложенные метод и алгоритмы.

5. Нейросетевые модели прогнозирования временного ряда налоговых поступлений (на примере Республики Бурятия) и прогнозирования результатов Единого государственного экзамена по данным профориентационного анкетирования, построенные с применением разработанного программного комплекса.

## СПИСОК ПУБЛИКАЦИЙ ПО ТЕМЕ ДИССЕРТАЦИИ

*В изданиях, рекомендованных ВАК РФ:*

1. Хандаров, Ф. В. Об одном эволюционном алгоритме настройки искусственных нейронных сетей / Т. Г. Дармаев, Ф. В. Хандаров // Вестник Бурятского государственного университета. Спецвыпуск В. – 2012. – С. 197-203.
2. Хандаров, Ф. В. Прогнозирование налога на доходы физических лиц с использованием искусственных нейронных сетей / Ф. В. Хандаров, З. Б.-Д. Дондоков // Вестник Бурятского государственного университета. Серия : Математика и информатика. – 2012. – Вып. 1 – С. 60-67.
3. Хандаров, Ф. В. Гибридный метод глобальной оптимизации на основе поиска с запретами и дифференциальной эволюции / Ф. В. Хандаров, Т. Г. Дармаев // Вестник Бурятского государственного университета. Выпуск: Математика, информатика. – 9 (1). – 2014. – С.69-75.

*В других научных изданиях:*

4. Прогнозирование поступлений налога на прибыль организаций с помощью искусственных нейронных сетей / Ф. В. Хандаров [и др.] // Нейроинформатика, её приложения и анализ данных : материалы XVI Всероссийского семинара (19–21 сентября 2008) / под ред. А. Н. Горбаня, Е. М. Миркеса. – Красноярск : ИВМ СО РАН, 2008. – С. 56-58.
5. Хандаров, Ф. В. Открытая кроссплатформенная библиотека для решения нейросетевых задач и инструментальная среда для быстрого создания нейронных сетей различных топологий / Ф. В. Хандаров, М. В. Скворцов // Нейроинформатика, её приложения и анализ данных : материалы XVI Всероссийского семинара (19-21 сентября 2008) / под ред. А. Н. Горбаня, Е. М. Миркеса. – Красноярск : ИВМ СО РАН, 2008. – С. 59-65.
6. Хандаров, Ф. В. Прогнозирование налоговых поступлений с использованием гибридных нейронных сетей / Ф. В. Хандаров, З. Б.-Д. Дондоков // Инфокоммуникативные и вычислительные технологии и системы : материалы III Международной конференции (6-11 сентября 2010). – Улан-Удэ : Изд-во БурГУ, 2010. – С. 272-275.
7. Хандаров, Ф. В. Прогнозирование поступлений налога на прибыль организаций на основе гибридных нейронных сетей / З. Б.-Д. Дондоков, Ф. В. Хандаров // Кулагинские чтения : XI Международная научно-практическая конференция. – Чита : ЗабГУ, 2011. – С. 151-153.
8. Прогнозирование поступлений налога на доходы физических лиц с использованием искусственных нейронных сетей / Ф. В. Хандаров [и др.] // Байкальские экономические чтения : материалы международной научно-практической конференции. – Улан-Удэ : Изд-во ВСГУТУ, 2011. – С. 195-198.