

ОПТИМИЗАЦИЯ ПРОГНОЗА НЕСТАЦИОНАРНЫХ ОБЪЕКТОВ НА  
ОСНОВЕ ГИБРИДНОГО АЛГОРИТМА ОБУЧЕНИЯ НЕЙРОННОЙ  
СЕТИ*Джуманов О.И., Холмонов С.М.*

Разработаны методические основы оптимизации обработки данных и обучения нейронных сетей (НС), ориентированных на применение эвристических алгоритмов поиска, стохастического моделирования, механизмов формирования субоптимальных наборов параметров обучения и данных, параметрической настройки вычислительных схем сети. Предложены модифицированные вычислительные схемы расчета весов, коэффициента синаптических связей, подбора активационной функции нейронов, рациональной архитектуры, числа слоев и нейронов в слоях сети при линейном и нелинейных зависимостях «входы и выходы». Построен обобщенный алгоритм обучения радиально-базисной сети с механизмами оптимальной настройки параметров, базы данных (БД), базы знаний (БЗ) и идентификации ортонормированными полиномами и авторегрессионной моделью и адаптивной сегментацией контура временных рядов. Варианты обобщения алгоритма обучения НС реализованы в составе программного комплекса обработки данных, для алгоритма доказана слабая чувствительность к размерности задач и способность к учету свойств информации.

**Ключевые слова:** нестационарный объект, прогнозирование, идентификация, обработка данных, точность, эвристический поиск, регулирование, адаптация, алгоритм обучения, нейронная сеть.

Эвристик кидириш алгоритмлари, стохастик моделлаштириш, ўргатувчи параметрлар ва маълумотларнинг субоптималь танламасини шакллантириш, ҳисоб схемаларини параметрик созлаш механизмларини қўллашга йўналтирилган нейрон тармоғини (НТ) макбул ўргатиш ва маълумотларга ишлов бериш услубий асослари ишлаб чиқилган. Нейрон микдорий, синаптик боғланиш коэффициентларини, активация функциясини, макбул тармоқ архитектурасини, қобиклар сони, қобикларда нейронлар сонини «кириш-чиқиш»нинг чизикли ва чизикмас боғланиш холларида ҳисоблашнинг такомиллашган схемалари таклиф этилган. Параметрларни, маълумот базасини (МБ), билимлар базасини (ББ) макбул созлаш, вақтлик катор контурини ортонормаллашган полиномлар ва авторегрессия модели

асосида идентификациялаш, адаптив сегментациялаш механизмларига асосланган радиал – базисли тармоқни ўргатувчи умумий алгоритм қурилган. НТни ўргатиш умумий алгоритми варианты ахборотга ишлов бериш дастурий мажмуаси таркибида жорийлашган, ҳамда унинг масала ўлчамига суэт сезгирлиги, маълумотлар хоссаларини инобатга олиш қобилиятига эга эканлиги исбот қилинган.

**Таянч иборалар:** ностационар объект, башорат қилиш, идентификациялаш, маълумотга ишлов бериш, аниқлик, эвристик қидириш, мувофиқлаштириш, мослаштириш, ўргатувчи алгоритм, нейрон тармоғи.

Effective tools are developed for data identification, analysis and processing on the basis of neural networks (NN) for forecasting random time processes (RTP) of non-stationary objects under conditions of a priori limitation, parametric uncertainty, low reliability, lack of an adequate model with the most effective optimization mechanisms. The offered technique assumes improvement of the computational schemes of traditional learning algorithms with direct and back error propagation based on least squares, gradient, modified gradient optimization, and allows eliminating the problems associated to laborious calculations of the exact values of global and local extremum search functions. Methods are developed for optimizing the learning of NN oriented on the use of heuristic search algorithms, stochastic modeling, formation of suboptimal set of training, regulation of parameters of NN components computational schemes with aim of improving the accuracy of data processing by smaller computations.

Computational schemes of networks structural components are designed for realizing the modified calculations of neurons weights, synaptic connections, activation function, rational architecture, number of layers and neurons in network layers, nonlinear dependences "inputs and outputs", executing of heuristic search, probabilistic calculations, adaptation of variables of objects description model and NN structural components, function of interconnections "inputs and outputs", hybrid training of NN under low costs, adjustments based on the optimal set of parameters, set of training data, database (DB), knowledge (KB).

Computational schemes are proposed for preliminary data processing with segmentation of random time series (RTS) in each interval of contour division, for selection of radial-basis function in each segment, regulation of segment boundaries and model parameter values

Algorithm constructed for NN learning uses sets of RTS templates and three-layer NN with a single hidden layer, a nonlinear activation function of neurons, and a mechanism for adjusting the parameters of network structural components. The effectiveness of RTS identifying method on the basis of orthonormal discrete polynomials in a system of equidistant points and effectiveness of use the mechanisms for tuning the dynamic characteristics, identification of stationary, quasistationary and nonstationary sections of RTS are substantiated.

**Keywords:** non-stationary object, forecasting, identification, data processing, accuracy, heuristic search, regulation, adaptation, learning algorithm, neural network.

## I. ВВЕДЕНИЕ

**Актуальность темы.** Нейронные сети (НС) служат эффективными инструментами идентификации, анализа, обработки данных при прогнозировании случайных временных процессов (СВП) нестационарных объектов в условиях априорной ограниченности, параметрической неопределенности, низкой достоверности, отсутствия адекватной модели, а также наиболее эффективных механизмов оптимизации обработки данных. Ключевым моментом исследования является построение практических приложений на основе технологии интеллектуального анализа данных (ИАД), в которых сохраняется значимость и необходимость разработки методов совершенствования и развития вычислительных схем обучения НС [1].

Традиционная методика предполагает применение вычислительных схем алгоритмов обучения с прямонаправленным и обратным распространением ошибок, а также оптимизацию на основе наименьших квадратов, градиентных, модифицированных градиентных методов. Однако оптимизация обучения НС при этих методах связана с трудоемкими вычислениями точных значений функций поиска глобального и локальных экстремумов, что в реальных условиях не всегда выполнимо [2].

Следовательно, большую значимость представляют подходы, направленные на совершенствование вычислительных схем компонентов и алгоритмов обучения НС, в которых предполагается включение эвристических алгоритмов поиска, основанных на механизмы извлечения статистических параметров, динамических характеристик информации.

Настоящая работа посвящена разработке методов оптимизации обучения НС, ориентированных на применение эвристических алгоритмов поиска, стохастического моделирования, механизмов формирования субоптимального набора обучения и регулирования параметров вычислительных схем компонентов НС для обеспечения большой точности обработки данных с меньшими вычислительными затратами.

## II. ОСНОВНАЯ ЧАСТЬ

**Конструктивные подходы и принципы построения модифицированных вычислительных схем обучения НС.** Для построения модифицированных вычислительных схем обучения НС необходимо исследовать следующие вопросы проектирования вычислительных схем [3,4]:

– построение структурных компонентов сети, которые реализуют процедуры модифицированных расчетов весов нейронов, коэффициентов синаптических связей, подбора активационной функции, рациональной архитектуры, определения числа слоев и нейронов в слоях сети, линейных и нелинейных зависимостей «входы и выходы»;

– организация эвристического поиска на основе вероятностных, эволюционных вычислений, адаптации переменных модели описания объектов и структурных компонентов НС, функции взаимосвязей между входами и выходами;

– разработка алгоритмов гибридного обучения НС, которая выполняется с меньшей ошибкой при небольших затратах за счет включения в структуру модели механизмов формирования, настройки оптимального набора параметров, набора обучающих данных, базы данных (БД) и базы знаний (БЗ).

Требуется, чтобы модифицированные вычислительные схемы обучения НС создавали широкую возможность при поиске локальных экстремумов и глобального минимума, повышения точности обработки данных, построения упрощенных и устойчивых алгоритмов, слабо чувствительных к размерности задач и способных к учету свойств данных.

**Оптимизация вычислительных схем обучения НС.** Основными требованиями, предъявляемыми к обучению сети является сохранение и использование сведений предыдущих успешных и неуспешных поисков, сокращение времени итерации, оптимизация обработки данных с применением механизмов настройки правил БЗ [3].

Протоколируются все запуски вычислительных схем, связанных с поиском и формированием оптимального набора параметров и набора обучающих данных, структурных компонентов, алгоритмов обучения НС, предварительной обработки данных, подбора адекватной модели для динамического описания нестационарных объектов [4].

Особенностью вычислительной схемы предварительной обработки данных является сегментация последовательности элементов случайных временных рядов (СВР) в каждом интервале разделения контура, подбор радиально-базисной функции для каждого сегмента, включение механизма регулирования границ сегментов, значений параметров модели описания. В алгоритме обучения НС используются еще наборы шаблонов СВР и модели идентификации.

Реализован трехслойный НС, который имеет единственный скрытый слой, нелинейную активационную функцию нейронов, включает механизм настройки параметров структурных компонентов сети. Алгоритм обучения НС задается следующими переменными:

$c = c_1, c_2, \dots, c_n$  – вектор, включающий координаты центра активационной функции нейронов скрытого слоя;

$\sigma_j$  – ширина окна активационной функции  $j$ -го нейрона скрытого слоя, которая выбирается в интервале  $\sqrt{n}/2 < \sigma < 3\sqrt{n}/2$ ;

$f(X, c) = e^{-\sum_{j=1}^n (x_j - c_j)^2 / \sigma^2}$  – радиально-симметричная активационная функция нейрона скрытого слоя;

$\omega_{ij}$  – вес связи между  $i$ -м нейроном исходного слоя и  $j$ -м нейроном скрытого слоя;

$H$  – емкость скрытого слоя сети, равного количеству шаблонов  $Q$ .

Обучение НС производится при следующих условиях и допущениях:

- нейроны в скрытом слое равны их синаптическим весам;
- центры активационных функций нейронов скрытого слоя размещаются в точках, входящих в набор шаблонов, как  $c_j = \bar{X}_j, j = 1, H$ ;
- ширина окна активационных функций нейронов для скрытого слоя  $\sigma_j, j = 1, H$  выбирается достаточно большая;
- веса нейронов  $w_{ij}, i = 1, Z, j = 1, H$  в исходном слое сети определяются по всем наборам шаблонов.

Шаблон  $p$ , представляемый для определения выхода  $i$ -го нейрона задается, как

$$\begin{aligned} Y_i &= w_{i1}f(\bar{X}_p, c_1) + w_{i2}f(\bar{X}_p, c_2) + \dots + w_{iZ}f(\bar{X}_p, c_Z) = \\ &= w_{i1}f(\bar{X}_p, X_1) + w_{i2}f(\bar{X}_p, X_2) + \dots + w_{iZ}f(\bar{X}_p, X_Z) = D_i. \end{aligned} \quad (1)$$

Для определения всего набора шаблонов задается решение системы уравнений в матричной форме

$$\Phi w^T = D, \quad (2)$$

где  $\Phi = \|f_{ij}\|_{i=1, H, j=1, Z}$  – интерполирующая поверхность матрицы  $f_{ij} = f(\bar{X}_i, \bar{X}_j)$ ;

$w = \|w_{ij}\|_{i=1, H, j=1, Z}$  – матрица синаптических весов исходного слоя НС;

$D = \|d_{ij}\|_{i=1, H, j=1, Z}$  – матрица исходных шаблонов.

Результаты решения отображаются следующей системой уравнений

$$w^T = \Phi^{-1}D, \quad (3)$$

которая должна обеспечивать прохождение интерполяционной поверхности в пространстве входных шаблонов.

Тестирование алгоритма оптимизации обучения сети требует нормирования входа  $x_{ij}$  НС, генерации псевдо случайных последовательностей  $c_i \in [0,1]$ , моделирования, чтобы выполнялось следующее условие

$$0 \leq \sum_{i=1}^n (x_{ij} - c_i)^2 \leq n. \quad (4)$$

**Построение механизма настройки параметров вычислительных схем компонентов и алгоритма обучения НС.** Предложены два подхода. В первом из них, предполагается оптимизация на основе применения алгоритма обучения сети с учителем. Механизм настраивает параметры структурных компонентов НС с учетом различных задающих внешних воздействий  $r(t)$  с целью достижения достаточного для практики качества обучения сети. Механизмом настройки параметров алгоритма обучения НС формируются следующие результаты:

- совокупность векторов  $V_i (i = 1, n)$ , характеризующих динамику задающего внешнего воздействия  $r(t)$ ;
- выхода  $y^*$  динамического идентификатора, синтезирующий алгоритм обучения НС с результатом  $y(t_{i+1})$ , в которых не учитывается внешнее воздействие;
- величину рассогласования  $e^*$  между результатами обучения НС  $y(t_{i+1})$  без учета и с учетом  $r(t_{i+1})$ ;
- параметры вычислительных схем НС корректируются с таким расчетом, чтобы минимизировать разницу  $r(t_{i+1}) - y(t_{i+1})$ , т.е. величины  $e^*$ .

Во втором подходе, рассматривается обучение НС без учителя с целью минимизации значения следующей квадратурной функции

$$E(t_j) = e^2(t_{i+1}) = (r(t_{i+1}) - y(t_{i+1}))^2 \rightarrow \min, \quad (5)$$

что требует применения численных методов оптимизации.

Однако, оптимизация обучения НС на основе численных методов, связана с трудностями следующего характера:

- расхождение результатов решения задач приводит к тому, что настраиваемые параметры компонентов НС не всегда оптимизирует обучение сети;
- в случае реализации поиска по овражной функции, либо функции с несколькими минимумами, процесс обучения НС производится слишком медленно, т.е. алгоритмы проявляют свойства много итеративности.

Для преодоления отмеченных недостатков реализован подход, направленный на применение гибридной вычислительной схемы обучения НС, включающей алгоритмы стохастического поиска, моделирования, представления нелинейных зависимостей «входы - выходы», настройки компонентов НС, правил БЗ, переменных моделей описания объектов и реализованного алгоритма обучения сети.

Доказано, что при этом обеспечиваются лучшие результаты по сравнению с другими методами эвристического поиска, а самое главное отсутствуют трудности, связанные с медленной сходимостью обучения сети.

Следующим подходом для исследования и разработки модифицированных вычислительных схем оптимизации обучения НС и адекватного описания нелинейных функциональных зависимостей «входы-выходы» является определение механизма, использующего динамические характеристики случайного процесса для настройки параметров.

Эффективность подхода обосновывается результатами задачи идентификации СВР на основе ортонормированных дискретных полиномов в системе равноотстоящих точек и применением механизмов настройки динамических характеристик [5].

**Описание случайных временных рядов на основе ортонормированных полиномов и механизма настройки.** Пусть задан класс линейных функций, характеризующих преобразования следующего вида [6]

$$Y(\tau) = \sum_{p=1}^k A_p \varphi_p \{X(t_1), \dots, X(t_r)\}, \quad (6)$$

где  $A_1, \dots, A_k$  - произвольные линейные операторы, действующие над функциями  $r$  переменных  $t_1, \dots, t_r$ ;

$\varphi_k(x_1, \dots, x_r)$  - произвольные функции  $r$  переменных;

$X(t) = \{X_i(t)\}$  - измерения СВР,  $i = \overline{1, I}$ .

Линейные операторы  $A_1, \dots, A_k$  в модели (6) определяются всевозможными значениями целых положительных чисел  $r$  и  $k$  в системе функций  $\varphi_1, \dots, \varphi_k$ .

Преобразование (6) считается линейным с аргументами  $t_1, \dots, t_r$ , когда задается в виде

$$U_p(t_1, \dots, t_r) = \varphi_p \{X(t_1), \dots, X(t_r)\}, \quad r = 1, k. \quad (7)$$

Тогда общий вид линейного преобразования (6) с учетом этой функции задается, как

$$Y(\tau) = \sum_{p=1}^k A_p U_p(t_1, \dots, t_r). \quad (8)$$

Нас интересует учет влияния внешнего воздействия, параметры которого определяет качества идентификации СВР.

Для решения такой задачи задаются линейные операторы  $A_1, \dots, A_k$  в виде линейных интегралов

$$A_p U_p(t_1, \dots, t_p) = \int_0^T \dots \int_0^T W_p(\tau, t_1, \dots, t_p) \psi(t_1, \dots, t_p) dt_1 \dots dt_p, \quad (9)$$

Для выполнения адекватного описания формируется матрица динамических характеристик на основе импульсно-переходной функции

$$W(\tau, t) = \left\| W_{j_0}(\tau, t) W_{j_1}(\tau, t_1) \dots W_{j_p}(\tau, t_1, t_2, \dots, t_p) \right\|, \quad (10)$$

где  $\tau, t \in (-\infty, \infty)$ ,  $i = \overline{1, I}$ ,  $j = \overline{1, J}$ ;

$$W(\tau, t_j) = 0 \quad \forall \tau, t < 0, \quad \tau, t > T, \quad 0 < T < \infty;$$

$I, J$  – число входов и выходов модели;

$W_{i1}, \dots, W_{ip}$  – вектор значений весовых функций компонентов  $i_1, \dots, i_p$ ;

$I$  – конечномерная матрица функции (10), как правило, задается гауссовым распределением с нулевым математическим ожиданием;

$K(t, \tau) = M[X(t) \times X^T(\tau)]$  – коэффициент динамической характеристики процесса, определяемый на основе функций (5) и задаваемый корреляционной матрицей;

$M$  – символ математического ожидания,  $\times$  – кронекеровская операция транспонирования  $T$ ;

$Y(t) = \{Y_j(t, \tau)\}$  –  $J$ -мерный вектор выхода модели.

Величина функциональной зависимости «входы-выходы» определяется в виде ряда Вольтера

$$\begin{aligned} Y_j(t, \tau) = & \sum_{i=1}^I \omega_{ji0}(\tau) + \sum_{i=1}^I \int_0^T \omega_{ji1}(\tau_1) X_1(t_1) dt_1 + \dots + \\ & + \sum_{i=1}^I \int_0^T \dots \int_0^T \omega_{jip}(\tau, t_1, \dots, t_p) X_1(t_1) \times \dots \times X_p(t_p) dt_1 \dots dt_p, \end{aligned} \quad (11)$$

где  $X_i(t)$  –  $i$ -я входная компонента процесса  $X(t)$ ;

$\omega_{ji}(t, \tau)$  – переходная функция входа  $X_i(t)$  и выхода  $Y_j(t)$ ;

$T_1, \dots, T_p$  – области интегрирования.

На практике обычно ограничиваются первыми тремя членами ряда (11), что создает возможность для получения динамических характеристик по типичной методике стохастического вероятностного анализа [5]:

для  $p = 1$ ,

$$K_{XY}(t) = \int_0^T K_{XX}(t - \tau) \omega(\tau) d\tau, \quad (12)$$

где  $K_{XX}(t) = Q(t)$  – взаимная корреляционная функция входной  $x(t)$  и выходной зависимости  $y(t)$ ;

$K_{XX}(t - \tau)$  – автокорреляционная функция входных данных  $x(t)$ ;

$\omega(t)$  – импульсно-переходная функция;

для  $p = 2$ ,

$$Q(t_1, t_2) = 2 \int_0^T \int_0^T K_{XX}(t_1 - \tau_1) \times K_{XX}(t_2 - \tau_2) \omega(\tau_1, \tau_2) d\tau_1 d\tau_2, \quad (13)$$

где

$$Q(t_1, t_2) = M[y(t)x(\tau - t_1)x(\tau - t_2)] - M[y(t)]K_2(t_1 - t_2).$$

Решена задача преобразования неизвестной функции  $\omega(\tau)$  в функцию  $K_{XY}(t)$ . Для этого задается операторное уравнение с учетом импульсно-переходной функции

$$K_{XX}\omega(\tau) = K_{XY}, \quad (14)$$

где  $\omega(\tau) \in D(K_{XX}) \leq Z$ ,  $K_{XY} \in F$ ;

$$R(K_{XX}) = K_{XX}[D(K_{XX})];$$

$D(K_{XX})$  и  $R(K_{XX})$  – области значений оператора  $K_{XX}$ .

В [6,7] эффективность разработанной методики обосновывается решением задач сегментирования, описания сегментов базис-функциями, определения динамических характеристик, выявления стационарных, квазистационарных и нестационарных участков СВР. Результаты сегментации контура СВР, аппроксимации базисными функциями используются при извлечении поведения динамики и свойств данных на участках разделения. Модель каждого однородного сегмента задается кортежами

$$M(A, \sigma, D_n),$$

где  $A$  – весовые коэффициенты;  $\sigma$  – погрешность сегментации;  $D_n$  – дисперсия ошибки сегментации, которая используется для обнаружения наличия скачка в нестационарной динамике СВР в момент  $t$  для проверки условия превышения пороговой величины  $D_0$ .

Разработан и реализован гибридный алгоритм обучения НС, включающий алгоритмы обучения прямого и обратного распространения ошибок, многошаговой идентификации СВР на основе ортогональных полиномов, сегментации по авторегрессионной модели, настройки переменных модели, вычислительных схем компонентов и алгоритма обучения сети.

**Применение гибридного алгоритма обучения НС для оптимизации прогноза СВР.** Для достижения адекватной идентификации СВР регулируются следующие параметры гибридного алгоритма [8]:

$n_0$  - начало сегмента;

$m_0$  - длина опорного окна;

$k_0$  - длина тестового окна;

$W_g, W_t, W_c$  - опорное, тестовое и расширяющиеся окна;

$\varepsilon_g, \varepsilon_t, \varepsilon_c$  - ошибки идентификации для соответствующего окна;

$s(n:m)$  - участок сегмента СВР;

$U_{inp}, U_{hid}, U_{out}$  - количество нейронов по слоям сети;

$H_g, H_t, H_c$  - логарифмические оценки правдоподобия для опорного,

тестового и расширяющегося окна;

$d$  - оценка расстояния;

$d(n)$  - порог для сравнения.

Механизм настройки переменных гибридного алгоритма выполняет проверки следующего условия:

- если  $d(n) < Th_1$ , то тестовое окно присоединяется к опорному окну и осуществляется сдвиг тестового окна;
- если  $d(n) > Th_1$ , то фиксируются границы сегмента.

Циклическая процедура создания набора окон продолжается до тех пор, пока не будут идентифицированы все сегменты СВР.

Для оптимизации обучения НС гибридным алгоритмом выполняются следующие процедуры:

- если набор предъявленного шаблона для сформированных однородных сегментов будет меньше, чем требуемого, то осуществляется слияние идентифицируемого сегмента с левым соседним сегментом;
- процесс обучения сети продолжается по динамике развития СВР до обнаружения нестационарных участков;
- формируются группы классов в виде стационарных, квазистационарных и нестационарных сегментов.

Другими дополнительными возможностями гибридного алгоритма являются объединение разбитых по классам сегментов на предыдущих итерациях, уменьшение числа итераций, расширение интервалов сегментирования и области значений настроечных параметров, как  $[0, C] \times [0, C] \times [0, C] \times \dots$ , где  $C$  - достаточно большое число; формирование оптимального набора переменных и обучающих данных [9].

Разработан программный комплекс обработки данных для идентификации и прогнозирования СВР на основе гибридного алгоритма обучения НС с настройкой параметров структурных компонентов и алгоритмов обучения сети и переменных моделей описания. Результаты тестирования программных модулей приведены в табл. 1.

Таблица 1.

Результаты тестирования программных модулей комплекса

Структура гибридного алгоритма обучения НС	Модули идентификации СВР	Число итераций алгоритма	Точность обработки данных в %.
Традиционные алгоритмы обучения НС	Типовые вычислительные схемы компонентов НС	$(2,5-3) \cdot 10^3$	68,7
Синтез алгоритма сегментации с традиционным	Авторегрессионные модели	$0,9 \cdot 10^3$	73
Модифицированное обучение НС с настройкой параметров	Модифицированные вычислительные схемы НС и сегментации	$0,6 \cdot 10^3$	78

КОМПОНЕНТОВ			
Синтез алгоритмов идентификации СВР с рекуррентной настройкой значений переменных модели	Ортогональные полиномы, нейросетевые, вычислительные схемы сегментации, механизмы настройки переменных	$2 \cdot 10^2$	82
Синтез алгоритмов идентификации СВР с настройкой параметров вычислительных схем компонентов НС	Ортогональные полиномы, нейросетевые, вычислительные схемы сегментации, настройки параметров сегментов и компонентов НС, модифицированного обучения НС	$0,8 \cdot 10^2$	87
Гибридный алгоритм обучения НС	Обобщенный алгоритм идентификации с механизмами настройки переменных модели	$0,6 \cdot 10^2$	92
Программный комплекс идентификации, обработки данных и прогнозирования СВР	Обобщенный алгоритм идентификации, гибридный алгоритм обучения НС, механизмы настройки БД и БЗ	$(0,4 - 0,5) \cdot 10^2$	94

### III. ЗАКЛЮЧЕНИЕ

Разработаны методические основы оптимизации обработки данных и построения приложений проблемных задач анализа и прогнозирования нестационарных объектов на основе гибридного описания, включающие модифицированные вычислительные схемы компонентов, алгоритмов обучения НС, сегментирования СВР, механизмов настройки параметров в условиях низкой достоверности и априорной недостаточности данных, нестационарности и неопределенности прогнозируемых процессов.

Для оптимизации обучения НС синтезированы вычислительные схемы радиально-базисной функции, ортонормированных полиномов, авторегрессионной модели с задержкой по времени, адаптивной сегментации, механизмов настройки параметров компонентов и алгоритмов обучения сети. Экспериментальными исследованиями обоснована эффективность разработанных алгоритмов обработки данных, при которых наилучшие результаты описания СВР достигаются ортонормированным дискретным

полиномом, в которых механизмы настройки переменных позволяют реализовывать динамические характеристики для адаптации и оптимизации прогноза нестационарных процессов.

Практическая ценность результатов реализованных алгоритмов обосновывается повышением точности обработки данных на 20–30 % при нестационарном процессе; на 10 - 12 % за счет алгоритма обучения НС с настройкой субоптимального набора параметров; 15 - 20 % за счет механизма регулирования квазистационарных участков сегментов СВР.

## ЛИТЕРАТУРА

- [1] Хайкин С. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006. - 1104 с.
  - [2] Чипига А.Ф., Воронкин Р.А. Обучение искусственных нейронных сетей путем совместного использования методов локальной оптимизации и генетических алгоритмов // Известия ТРТУ. Т. 33. №4. - с.172-174.
  - [3] Жуманов И.И. Оптимизация обработки изображений микрообъектов на основе рекуррентного обучения нейронной сети и имплицитного отбора информативных признаков// Узбекский журнал «Проблемы информатики и энергетики», Издательство «Фан» АН РУз. - Ташкент.-2016, №4.-с.12-20.
  - [4] Жуманов И.И. Оптимизация обработки данных нестационарных объектов на основе нечетких моделей идентификации с настройкой параметров. Журнал «Вестник ТУИТ». - Ташкент, 2017. - №1(41)/2017. - с. 34-47.
  - [5] Нейросетевая модель анализа технологических временных рядов в рамках методологии Data Mining / А. М. Вульфин, А. И. Фрид // Информационно-управляющие системы. 2011. № 5. - с.31–38.
  - [6] Применение методов сегментации к обработке геофизических данных / В. В. Геппенер, А. Б. Тристанов, П. П. Фирстов // Комплексные сейсмологические и геофизические исследования Камчатки КСиГИК-2006. Матер. Всерос. науч.-техн. конф., 2006. С. 183-187.
  - [7] Алексеев А.Ф., Алексеев: Ф.Ф., Дегтярев Г.Л. Синтез нелинейных нечетких алгоритмов управления на основе метода векторных функций Ляпунова// Вестник КГТУ. 2012. №4. - с.247-255.
  - [8] Jumanov I.I., Bekmurodov Z.T. Algorithms of properties extraction and informative attributes selection on the basis of mellin transformation and parallel calculations. // Всемирная конференция «Интеллектуальные системы для индустриальной автоматизации» - WCIS-2016, 25-27 октябрь 2016 г., ТГТУ, Ташкент. – с. 77 - 81.
- Жуманов И.И., Бекмуродов З.Т. Повышение точности обработки данных нестационарных объектов на основе оптимизации набора параметров гибридной модели идентификации // XII Международная Азиатская школа-семинар «Проблемы оптимизации сложных систем», СО РАН, 12-16 декабрь 2016 г., Новосибирск. – с. 192 - 201.