

## КОМПЕНСАЦИЯ ОШИБОК ОПЕРАТОРА В КОНТУРЕ УПРАВЛЕНИЯ СЛЕДЯЩЕЙ СИСТЕМЫ НА ОСНОВЕ СИНТЕЗИРУЕМЫХ ВЕЙВЕЛЕТ- СЕТЕЙ

Литвиненко В.И., Четырин С.П.

### Введение в проблему

Наличие оператора в контуре слежения за целью требует учёта психофизиологических способностей человека при формировании структуры и характеристик машинной части системы слежения.

В настоящее время сложились определённые представления о процессах, качественно характеризующих работу оператора в контуре слежения [1,2,3]:

- разрешение сетчатки глаза, передача сигнала в кору головного мозга, выработка сигналов управления, передача сигналов к исполнительному органу и прохождение сигнала обратной связи происходит с некоторой задержкой  $\tau_3$ , величина которой порядка 0,2÷0,4 с. Запаздывание выполнения ответных действий на возникший стимул не является постоянной величиной, оно меняется как от изменения условий работы, так и от способностей конкретных индивидуумов. Для конкретного оператора оно также меняется, в процессе работы в зависимости от напряжённости выполняемой работы, утомляемости, тренированности и т.п.;

- в первом приближении при относительно узком диапазоне движений исполнительного органа (рука, голова и т.п.) человека-оператора можно считать линейным звеном, что позволяет проводить анализ качества слежения оператором за целью методами линейных систем автоматического управления;

- человек-оператор в переходном процессе, в среднем ведёт себя как реальное интегрирующее звено;

- человек является весьма пластичным звеном и, как правило, подстраивает свою передаточную функцию (структуру и параметры) под амплитудно-частотные характеристики сигнала, т.е. адаптируется под них;

- наблюдение ошибки слежения во времени сопровождается оценкой скорости её изменения, что позволяет создать представление о величине упреждённого значения ошибки на время упреждения  $T_y$ ;

- оператор, находясь на качающемся основании, включает в процесс слежения не только зрительную информацию, но и сигналы органов равновесия, что приводит к существенному повышению точности слежения. По экспериментальным данным в зависимости от типа объекта управления относительная величина дисперсии ошибки слежения при использовании сигналов органов равновесия снижается от 20 до 50%.

Исходя из сложившихся представлений и на основе экспериментальных исследований, приведенных в [3], для моделирования функционирования следящей системы может быть выбрана передаточная функция звена «человек-оператор» в виде

$$\Phi_{on}(p) = \frac{e^{-\tau_3 p}}{(T_{on} p + 1)^2} \quad (1)$$

Однако параметры и вид функции могут быть разными не только для разных операторов, но и для одного и того же в различных условиях. Таким образом, системы слежения, в которых человек включен в контур управления, можно отнести к классу систем управления с неполной информацией, со сложной, немоделируемой динамикой и неконтролируемым изменением собственных свойств.

Поэтому для компенсации ошибки оператора в контуре следящей системы предлагается построить его идентифицирующую модель на основе вейвлет-сетей.

**Постановка задачи:** Разработать методику создания и настройки идентифицирующих вейвлет-нейронных сетей при помощи искусственных иммунных систем для компенсации ошибки человека-оператора в контуре управления следящей системы.

### Решение задачи

#### 1. Вейвлет-преобразования

Вейвлет («всплеск», «выброс», «короткая волна») представляют собой волновые функции, способные осуществлять преобразование Фурье не по всей временной оси, а локально по месту своего расположения. Вейвелеты используют в случаях, когда результат анализа исследуемого сигнала должен содержать не только перечисление его характерных частот (масштабов), но и сведения об определенных локальных координатах, при которых эти частоты проявляют себя. Основным полем применения вейвлет-анализа является анализ и обработка нестационарных (во времени) или неоднородных в (пространстве) сигналов разных типов. Общий принцип построения базиса вейвлет-преобразования и смещений. Любой из наиболее часто применяемых вейвелетов порождает полную ортонормированную систему функций с конечным носителем, построенную с использованием масштабного преобразования сдвигов. За счет изменения масштабов вейвелетов способны выявить различие в характеристиках на разных шкалах, а путем сдвига проанализировать свойства сигнала в разных точках на всем изучаемом интервале. При анализе нестационарных сигналов за счет свойств локальности вейвелеты имеют существенное преимущество перед преобразованием Фурье.

Непрерывное вейвлет-преобразование является скалярным произведением  $f(x)$  и базисных функций.

$$\varphi_{\sigma,c} = \sigma^{-1/2} \varphi\left(\frac{x-c}{\sigma}\right), \sigma \in R^+, c \in R \quad (2)$$

Базисные функции  $\varphi_{\sigma,c} \in L^2(R)$  являются вещественными и колеблются вокруг оси абсцисс. Они определены на некотором интервале. Данные функции называются вейвелетами и могут рассматриваться как масштабируемые и сдвинутые версии материнской функции  $\varphi(x)$ . Параметр  $c$  показывает смещение во времени, а  $\sigma$  - параметр масштаба. Большое значение  $\sigma$  соответствует низким частотам, малые – высоким. Множитель  $\sigma^{-1/2}$  является нормирующим в  $L^2$ -пространстве, другими словами если материнский вейвлет имел норму равную 1. Операция умножения на окно содержится как бы в самой базисной функции, которая позволяет сужать и расширять это окно. Отсюда появляется возможность адаптивного выбора параметров окна для соответствующего сигнала.

#### 2. Вейвлет-нейронной сети

Вейвлет-нейронные сети являются нейронными сетями с прямой передачей данных с одним скрытым слоем, где в качестве базисных функций используются семейства ортонормированных вейвелетов. Вейвлет-нейронные сети сочетают в себе нейронные сети с прямой передачей данных и аппарат основанный на вейвлет-декомпозиции. Основная идея вейвлет-декомпозиции состоит в разложении сигнала  $f(x) \in L^2(R^n)$  в ряд функций, зависящих от растяжений смещений материнского вейвелета. Эти функции в таком случае представляют нейронные сети типа перцептрон. В большинстве работ по вейвлет-нейронным сетям в качестве активационных функций используют простейшие типы вейвелетов, таким образом используя малую часть преимуществ теории вейвелетов.

Свойства таких вейвлет-нейронных сетей определяется активизационными вейвлет-функциями, которые состоят из сдвигов и растяжений материнского вейвлета. Преимуществами вейвлет-функций является то, что они имеют вид, локализованный во времени(или пространстве) волновых пакетов с нулевым затягиванием интеграла, обладают возможностью сдвига во времени, способны к масштабированию(сжатию-растяжению), а также имеют локальный частотный спектр [ 4,10,11].

Аппроксимируемый сигнал  $\hat{y}$  вейвлет-нейронной сети может быть формально представлен

$$\hat{y}(t) = u(t) \sum_{k=1}^K w_k h_{a_k, b_k}(t) \quad (3)$$

Структура вейвлет-нейронной сети, используемой в данной работе для построения модели временного ряда, представлена на рисунке 1.




Рис. 1. Структура вейвлет-нейронной сети

Параметры нейронной сети  $w_k$ ,  $a_k$ , и  $b_k$  (вес, масштаб и сдвиг по временной оси) являются настраиваемыми параметрами которые необходимо оптимизировать, свертывая функцию стоимости или функцию энергии,  $E$ , на исследуемый временной промежуток  $t$ . Таким образом, что

$$e(t) = y(t) - \hat{y}(t), \quad (4)$$

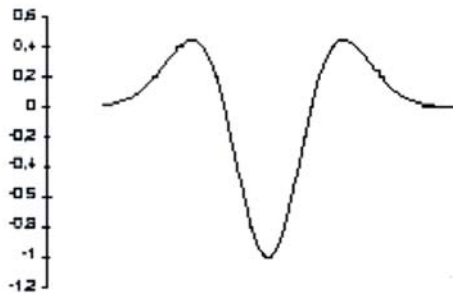
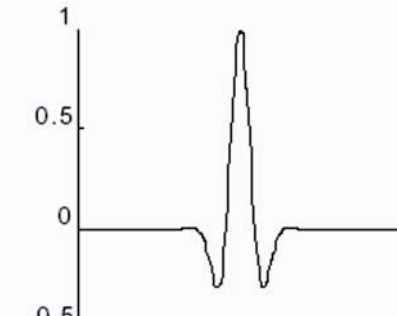
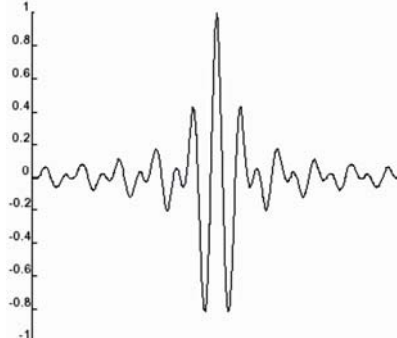
которое является переменной от ошибки функции времени  $t$ , где  $y(t)$  является целевой функцией. Функция энергии определяется как

$$E = \frac{1}{2} \sum_{t=1}^T e^2(t) \quad (5)$$

В качестве параметров вейвлета используется его масштаб и сдвиг по временной оси. В представленной работе рассматривается сеть, использующая один тип вейвлета, а именно вейвлет «Мексиканская шляпа» (рис. 2), аналитическое выражение которого выглядит так:

В качестве материнских вей вейвлетов использовались, вей влеты «Мексиканская шляпа», «Морлета» и «Шеннона».

Для настройки параметров вейвлет сетей, наиболее широкое распространение получили методы, минимизирующие критерий обучения, связанный, с квадратами рассогласований между внешним обучающим сигналом  $d_j[k]$  и выходом сети  $\hat{y}_j(k)$ .

Используемые вейвлеты		
Имя вейвлета	Определение	Графическое представление
Мексиканская шляпа	$\left(\frac{2}{\sqrt{3}}\pi^{-\frac{1}{4}}\right)(1-x^2)e^{-\frac{x^2}{2}}$	
Морлет	$\cos(\omega_0\tau)\exp(-0.5\tau^2)$	
Шеннон	$\frac{\sin 2\pi\tau - \sin \pi\tau}{\pi\tau}$	

Простейшей из этих процедур является алгоритм Уидроу-Хоффа, минимизирующий при каждом такте локальный критерий

$$E_j(k) = \frac{1}{2} \left( d_j(k) - \hat{y}_j(k) \right)^2 = \frac{1}{2} e_j^2(k) \quad (6)$$

Обладая высоким быстродействием, а следовательно и выраженными следящими свойствами, эта процедура плохо работает в условиях помех, искажающих обрабатываемые сигналы, в связи с чем при работе со стохастическими процессами чаще всего применяется метод наименьших квадратов.

Процедуры, связанные с методом наименьших квадратов, минимизируют критерий (7):

$$E_j^k = \sum_{p=1}^k E_j(p) = \frac{1}{2} \sum_{p=1}^k e^2(p), \quad (7)$$

заданный на всей обучающей выборке и фактически обеспечивают решение системы нормальных уравнений.

Несмотря на положительные свойства описанных подходов обучения вейвлет-нейронных сетей, открытым остается вопрос выбора топологии (количество нейронов внутреннего слоя) вейвлет-нейронной сети. На практике это относится к чисто эмпирической процедуре. Хотя, учитывая рассмотренные свойства вейвлетов (сжатие и растяжения) количество вейвлет-нейронов в вейвлет-нейронной сети оказывает прямое влияние на качество аппроксимации стохастического сигнала.

В качестве функции активации выходного слоя исполу зовалась линейная функция активации:

$$f(Z) = Kz \quad (8)$$

$$K = const$$

Для решения данной проблемы нами предложено использовать алгоритм клонального отбора, который является одним из алгоритмов искусственной иммунной системы.

### 3. Применение искусственной иммунной системы

Искусственные иммунные системы [5,6] представляют собой методику решения задач, основанную на биологических принципах естественных иммунных систем позвоночных животных и человека. ИИС преимущественно используются для решения двух больших классов задач: оптимизации и распознавания. Как и естественные иммунные системы, ИИС используют модель распознавания чужеродных структур (антигенов) специальными рецепторами – антителами. Существует несколько разновидностей ИИС. В данной работе используется ИИС, основанная на принципах клонального отбора, реализованная в виде алгоритма клонального отбора (CLONALG), детальное описание которого приведено в [7]. Очевидно, что ИИС представляет собой идеализированный вариант ее естественного аналога, и воспроизводит лишь ключевые составляющие природного процесса. Этими составляющими являются: отбор лучших антител популяции в зависимости от степени их афинности антигену, клонирование антител, гипермутация и редактирование рецептора. С точки зрения ИИС, каждое антитело представляет собой один вариант решения задачи, закодированный в виде строки бит или символов. Способ кодирования антител зависит от структуры задачи и ее принадлежности к той или иной предметной области. Кроме того, от типа задачи, также, зависит и способ оценки антител, т.е. вид функции афинности. Разработка лишь этих двух составляющих дает возможность полностью адаптировать ИИС для решения задач в выбранной предметной области.

Отличительной чертой алгоритма клонального отбора и преимущество его перед генетическими алгоритмами, является его способность избегать локальные минимумы, что обусловлено действием операторов замещения и гипермутации. Операторы замещения в иммунной системы связаны с понятием иммунной метадинамики, который также носит название *механизма иммунного пополнения* и позволяет осуществлять отбор новых элементов согласно общему состоянию системы, что означает, чувствительность системы к этому новому элементу. Данная чувствительность обычно измеряется аффинностью, которую имеет этот элемент с действительно уже существующими элементами.

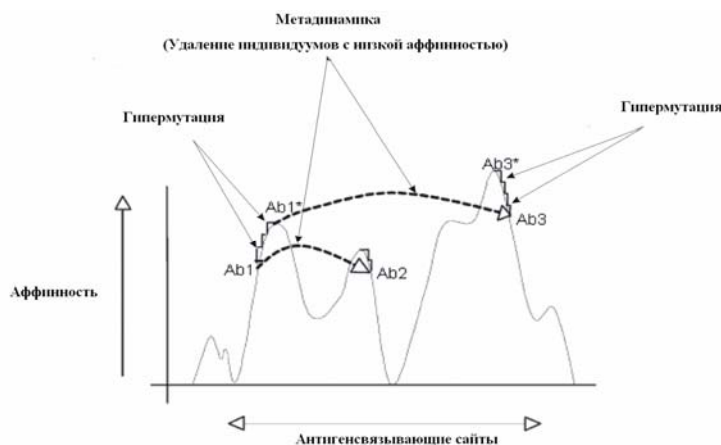


Рис. 2 Гипотетическое изображение поиска в пространстве аффинности

Формально алгоритм клональной селекции можно представить следующим образом:

$$CLONALG = (P^l, G^k, l, k, m_{Ab}, \delta, f, I, \tau, AG, AB, S, C, M, n, d), \quad (9)$$

где  $P^l$  – пространство поиска (пространство форм);  $G^k$  – представление пространства;  $l$  – длина вектора атрибутов (размерность пространства поиска);  $k$  – длина рецептора антитела;  $m_{Ab}$  – размер популяции антител;  $\delta$  – функция экспрессии;  $f$  – функция аффинности;  $I$  – функция инициализации начальной популяции антител;  $\tau$  – условие завершения работы алгоритма;  $AG$  – подмножество антигенов;  $AB$  – популяция антител;  $S$  – оператор селекции;  $C$  – оператор клонирования;  $M$  – оператор мутации;  $n$  – количество лучших антител, отбираемых для клонирования;  $d$  – количество худших антител, подлежащих замене новыми.

Рассмотрим пространство форм ( $P^l$ ) фенотипов и пространство их представлений в виде антител ( $G^k$ ) или пространство генотипов. Функция

$$\delta: P^l \rightarrow G^k \quad (10)$$

является функцией преобразования вариантов решений из  $P^l$  в их внутренние представления ( $G^k$ ) в виде индивидуумов популяции. Эта функция иначе называется функцией экспрессии. Предполагается, также, что для каждого решения  $p \in P^l$  существует одно и только одно его представление  $\delta(p) \in G^k$ . При этом в общем случае обратное утверждение неверно. Используя обобщенное представление, можно ввести функцию аффинности  $f$ :

$$f: P^l \times P^l \rightarrow \mathfrak{R}^+. \quad (11)$$

При этом задача состоит в максимизации функции аффинности.

Принимая начальный размер популяции антител ( $m_{Ab}$ ), можно ввести функцию инициализации в виде:

$$I: G^k \times m_{Ab} \rightarrow AB(G^k). \quad (12)$$

Часто инициализация производится случайным образом с использованием равномерного распределения.

Пусть  $Q$  – унарный стохастический оператор преобразования на множестве  $G^k$ , который использует управляющее множество  $K_Q$  для генерации управляющих параметров, определяющих способ преобразования на текущем шаге работы алгоритма. Следовательно, функциональная запись оператора  $Q$  может быть представлена так:

$$Q: G^k \times K_Q \rightarrow G^k. \quad (13)$$

Оптимальным решением  $Ab_{opt} \in G^k$  относительно оператора  $Q$  и антигена  $Ag \in AG$ ,  $AG \subset G^k$  называется индивидуум, чья аффинность не может быть увеличена при дальнейшем воздействии оператора преобразования  $Q$ , т.е.

$$\forall k \in K_Q: f(Q(Ab_{opt}, k), Ag) \leq f(Ab_{opt}, Ag). \quad (14)$$

Условие останова ( $\tau$ ) выполняется когда популяция антител полностью распознает популяцию антигенов, т.е.

$$\forall Ag \in AG: \exists Ab \in G^k \mid Ab = Ab_{opt}. \quad (15)$$

Оператор селекции  $S$  формирует подмножество  $G_S$  индивидуумов, чья аффинность является лучшей в данном поколении. Таким образом,  $S$  совместно с управляющим множеством  $K_S$  представляет функцию:

$$S: G^k \times K_S \rightarrow \{0, 1\}, \quad (16)$$

множество, которое образуется в результате селекции:

$$G_S = \{Ab \in G^k \mid S(Ab, k_S) = 1\}, \quad |G_S| = n. \quad (17)$$

Аналогично производится отбор индивидуумов в популяцию клеток памяти.

Оператор клонирования  $C$  увеличивает представительство элементов множества  $G_S$  в популяции и совместно с управляющим множеством  $K_C$  может быть записан так:

$$C : G_S \times K_C \rightarrow G_S. \quad (18)$$

Оператор мутации  $M$  с управляющим множеством  $K_M$  :

$$M : G^k \times K_M \rightarrow G^k. \quad (19)$$

Метадинамика системы выражена в виде функции замещения худших антител популяции:

$$R : G^k \times d \rightarrow AB_d(G^k). \quad (20)$$

Худшие антитела предварительно отбираются при помощи оператора селекции.

Ниже приводится обобщенное пошаговое описание алгоритма.

Шаг 1. *Инициализация.* Создание (обычно случайной генерацией) начальной популяции антител ( $AB$ ).

Шаг 2. *Вычисление аффинности.* Для каждого антитела  $Ab_j$ ,  $Ab_j \in AB$  вычислить его аффинность по отношению к каждому антигену  $Ag_i$ ,  $Ag_i \in AG$ . Результаты записать в матрицу аффинностей  $D : D = [|AG| \times m_{Ab}]$  и  $d_{ij} = f(Ab_j, Ag_i)$ ,  $d_{ij} \in D$ .

Шаг 3. *Клональная селекция и распространение.* Выбрать из популяции по  $n$  лучших антител для каждой строки матрицы  $D$ , и поместить их в отдельную популяцию клонов  $AB_C$ ,  $|AB_C| = n \cdot |AG|$ . Генерировать клоны элементов популяции  $AB_C$  пропорционально их аффинности, т.е. чем выше аффинность, тем большее количество клонов создается и наоборот.

Шаг 4. *Созревание аффинности.* Подвергнуть мутации все клоны популяции  $AB_C$  с вероятностью обратно-пропорциональной их аффинностям, т.е. чем ниже аффинность индивидуума, тем выше вероятность его мутации. Вычислить новую аффинность каждого антитела  $Ab_j$ ,  $Ab_j \in AB_C$  аналогично п.2, получив матрицу аффинностей  $D_C$ . Выбрать из популяции  $AB_C$   $n$  антител, для которых соответствующий вектор-столбец матрицы  $D_C$  дает лучший обобщенный результат аффинности, и перенести их в популяцию клеток памяти  $M_R$ .

Шаг 5. *Метадинамика.* Заменить  $d$  худших антител популяции  $AB$  новыми случайными индивидуумами.

Шаг 6. Заменить  $n$  антител популяции  $AB$  клетками памяти из  $M_R$  и перейти к п.2 пока не будет достигнут критерий останова.

Особенностью алгоритма клональной селекции является то, что он, в отличие от иммунной сети, поддерживает постоянный размер популяции антител.

В представленной работе ИИС используется для оптимизации параметров вейвлет-нейронной сети, следовательно, каждое антитело должно содержать в себе информацию о структуре и значениях параметров для одного варианта вейвлет-нейронной сети. Структура антитела, разработанной ИИС представлена на рисунке 3.




Рис. 3 Структура антитела ИИС

Антитело состоит из семи частей. Первая часть представляет собой стоку определяющая максимальное число выбранных нейронов, кодирующую структуру скрытого слоя вейвлет-нейронной сети. Раздел вейвлет-коэффициентов содержит значения масштабов и временных сдвигов соответствующих вейвлетов, раздел весов выходного слоя определяет значение весов выходного слоя, пятая часть содержит тип активизационной функции и в самом конце строки находится раздел параметров активизационной функции выходного слоя.

Для оценки антитела, клональный алгоритм воспроизводит соответствующий его структуре вариант вейвлет-нейронной сети и рассчитывает среднеквадратическую ошибку спрогнозированной сетью и реальных значений временного ряда на обучающей выборке данных. Эта ошибка становится мерой афинности соответствующего антитела популяции.

#### 4. Экспериментальные исследования

Проведён компьютерный эксперимент. Для моделирования были сгенерированы двумерный массив, содержащий воздействие на оператора и реакция оператора на воздействия. Необходимо по реакции оператора определить величину воздействия.

Тренировочная выборка состояла из 11315 измерений, тестовая из 10382 измерений.

В качестве постоянных параметров настройки использовались:

Условие останова 100 поколений

- % отбора лучших индивидуумов из популяции 0,7
- Общий уровень мутации 0,8
- Жесткость отбора (селективное давление) 20

В качестве изменяемых параметров:

- Размер основной популяции индивидуумов 50, 100, 300
- Размер популяции клонов 25, 300
- Максимальное количество нейронов верхнего слоя: 52, 78, 156.

Оценка и выбор полученных моделей оценивалась с помощью множества статистических параметров. Они разрешают оценить в отдельности значимость, определить интегральную погрешность модели относительно исходных данных, установить наличие корреляции между значениями ошибки модели, а также определить степень адекватности модели физическому процессу в целом. В это множество входят такие статистические параметры:

**1. Коэффициент детерминации  $R^2$ .** Мерой информативности временного ряда часто используют его дисперсию. Коэффициент  $R^2$  - это отношения дисперсии той части временного ряда основной переменной, что описывается полученным уравнением, к выборочной дисперсии этой переменной. Он исчисляется по формуле:  $R^2 = \frac{\widehat{\text{var}}(a)}{\text{var}(y)}$ .

Очевидно, что для адекватной модели коэффициент детерминации должен направляться к единице, то есть:  $R^2 \rightarrow 1$ .

**2. Сумма квадратов ошибок модели  $\sum e^2(k)$ ,** то является  $SSE = \sum_{k=1}^N [\widehat{y}(k) - y(k)]^2$ , где  $\widehat{y}(k) = \widehat{a}_0 + \widehat{a}_1 \widehat{y}(k-1) + \widehat{a}_2 \widehat{y}(k-2) + \widehat{b}_1 x(k) + \widehat{b}_2 z(k)$ ;



$y(k)$  – измерения;  $N$  – длина выборки. Очевидно, что из возможных кандидатов необходимо выбирать ту модель, для которой  $\sum e^2(k)$  принимает минимальное значение.

**Статистика Фишера  $F$** , что определяет степень адекватности модели в целом. Для адекватной модели выполняется условие:  $F > F_{крит}$ , где  $F_{крит}$  определяется по таблице аналогично  $t$  – статистике. Значение  $F$  пропорционально  $R^2 / (1 - R^2)$ , где  $R^2$  – коэффициент детерминации. Таким образом, большему значению  $F$  отвечает более адекватная модель.

**Среднеквадратическая ошибка**, определяет точность прогноза и рассчитывает

точность прогноза по формуле:  $RMSE = \sqrt{\frac{\sum_t^N (\hat{y}_t - y_t)^2}{N}}$ , где  $\hat{y}_t$  – вычисленное значение,  $y_t$  – фактическое значение,  $N$  – объем выборки.

**Критерий Колмогорова-Смирнова** – одновыборочный критерий нормальности, основан на максимуме разности между кумулятивным распределением выборки и предполагаемым кумулятивным распределением. Применени данного критерия обусловлено тем, что, остатки  $e_i$  должны бать независимми нормально распределенными случайными величинами с нулевым средним. Статистика критерия – абсолютная величина разности эмпирической  $F^*(x)$  и теоретической  $F(x)$  функций распределения:

Находится наибольшая разность между эмпирической  $F^*(x)$  и теоретической  $F(x)$  функциями распределения:  $D = \max |F(x_i) - F^*(x_i)|$  ( $i=1,2,\dots,k$ ).

Находится величина  $\lambda = D\sqrt{n}$  по таблице находится вероятность  $p(\lambda)$  того, что расхождение  $D$  между  $F(x)$  и  $F^*(x)$  носит случайный характер. Если эта вероятность велика, то нет оснований, считать, что гипотеза о законе распределения несправедлива, если же  $p(\lambda)$  мала (обычно меньше 0,1), то нулевая гипотеза нуждается в дополнительной проверке, так как есть основания считать, что распределение величины  $X$  не описывается удовлетворительно выбранной функцией. В зависимости от выдвинутой (так называемой нулевой) гипотезы подсчитывают значения эмпирических квантилей  $z_i$  для **правых** значений интервалов  $x_i$ . Затем по находятя значения функции нормального распределения  $F(z)$ , представляющие вероятность того, что наблюдаемое значение  $x$  будет меньше правого конца  $x_i$  интервала с номером  $i$ .

Далее, согласно критерию Колмогорова, находится наибольшая разность  $D$  и затем –  $\lambda$ . По таблице . 1 оценивается вероятность справедливости нулевой гипотезы. Если статистика Колмогорова-Смирнова значима, то гипотеза о том, что соответствующее распределение нормально, должна быть отвергнута, т.е. если  $D$  статистика Колмогорова-Смирнова значима, то гипотеза о том, что соответствующее распределение нормально, должна быть отвергнута. Для проведения эксперимента использовалась компьютерная программа, в которой моделируется текущее положение объекта слежения (цели) и фиксируются текущие координаты положения курсора манипулятора «мышь» и ошибки оператора при слежении оператора за целью с помощью мыши.


Точность полученных моделей вейвлет нейронных сетей при различных вейвелетах, количестве нейронов, заданных параметрах настройки объема популяции и максимальном количестве клонов

Тип вейвлета	Верхний допустимый максимум количества нейронов	Фактическое количество нейронов	Отношение: Популяция/К-во клонов	RMSE
MexicaHat	52	30	50/300	0,020
MexicaHat	78	31	50/300	0,019
MexicaHat	156	88	50/300	0,032
MexicaHat	52	20	300/300	0,022
MexicaHat	78	47	300/300	0,091
MexicaHat	156	80	300/300	0,042
MexicaHat	52	20	100/25	0,016
MexicaHat	78	47	100/25	0,024
MexicaHat	156	80	100/25	0,074
Morlet	52	29	50/300	0,035
Morlet	78	40	50/300	0,028
Morlet	156	76	50/300	0,028
Morlet	52	27	300/300	0,051
Morlet	78	43	300/300	0,077
Morlet	156	84	300/300	0,103
Morlet	52	27	100/25	0,050
Morlet	78	43	100/25	0,049
Morlet	156	84	100/25	0,115
Shennon	52	25	50/300	0,020
Shennon	78	36	50/300	0,054
Shennon	156	69	50/300	0,045
Shennon	52	24	300/300	0,100
Shennon	78	26	300/300	0,086
Shennon	156	82	300/300	0,234
Shennon	52	24	100/25	0,145
Shennon	78	26	100/25	0,261
Shennon	156	82	100/25	0,243

Получена оценка ожидаемой эффективности разработанной методики нейросетевой компенсации ошибок слежения. В качестве показателя эффективности принята среднеквадратическая ошибка слежения. Анализ результатов эксперимента показал, что использование нейросетевой компенсации на основе вейвлет-сетей позволит уменьшить ошибку слежения в несколько раз.

Анализ остатков и коэффициент детерминации


Тип вейвлета	Фактическое количество нейронов	Колмогорова-Смирнова	p-значение	Сумма квадратов ошибок	Коэффициент детерминац.
MexicaHat	30	0,078	0,010	4,342	0,985
MexicaHat	31	0,056	0,010	3,377	0,998
MexicaHat	88	0,076	0,010	10,698	0,963
MexicaHat	20	0,910	0,010	5,183	0,941
MexicaHat	47	0,021	0,010	86,219	0,995
MexicaHat	80	0,086	0,010	18,285	0,991
MexicaHat	20	0,070	0,010	2,758	0,946
MexicaHat	47	0,088	0,010	6,145	0,994
MexicaHat	80	0,082	0,010	56,809	0,556
Morlet	29	0,102	0,010	12,574	0,915
Morlet	40	0,071	0,010	4,342	0,900
Morlet	76	0,064	0,010	7,995	0,992
Morlet	27	0,061	0,010	26,984	0,990
Morlet	43	0,127	0,010	60,774	0,429
Morlet	84	0,070	0,010	109,191	0,994
Morlet	27	0,142	0,010	26,257	0,988
Morlet	43	0,129	0,010	25,004	0,992
Morlet	84	0,131	0,010	136,940	0,941
Shennon	25	0,103	0,010	4,153	0,975
Shennon	36	0,137	0,010	30,772	0,906
Shennon	69	0,078	0,010	21,372	0,988
Shennon	24	0,108	0,010	102,894	0,908
Shennon	26	0,110	0,010	76,358	0,786
Shennon	82	0,071	0,010	568,241	0,382
Shennon	24	0,138	0,010	216,989	0,645
Shennon	26	0,093	0,010	708,098	0,579
Shennon	82	0,084	0,010	646,148	0,038



а



б



в

Рис. 5 Зависимость адекватности нейросетевой модели от количества нейронов внутреннего слоя при F- критическом 1,033

## 5. Выводы

В данной работе рассмотрена методика создания и настройки вейвлет-нейронных сетей при помощи искусственных иммунных систем. На базе этой методики разработана программа, которая была протестирована посредством решения задачи компенсации ошибок оператора при слежении за целью на экране монитора с помощью манипулятора. Приведенные в работе примеры показывают высокие результаты тестирования вейвлет-нейронной сети, работающей под управлением ИИС. В качестве направления дальнейших исследований предлагается расширение существующей системы путем добавления других архитектур вейвлет-нейронных сетей, а также проведение сравнительных тестов с рядом разновидностей иммунных алгоритмов.

Models neural wavelet networks for the decision of a problem of indemnification of errors of the operator-tipper-of in a contour of management of system watching the purpose are developed and investigated. Comparative researches of accuracy and adequacy of the received models are carried out.

1. Луизов А.В. Инерция зрения. –М.: Оборонгиз, 1961, 0206с.
2. Луизов А.В., Травникова Н.П. Вероятность обнаружения движущихся объектов. –М.: Светотехника, 1984, с.7-9.
3. Цибулевский И.Е. Человек как звено следящей системы – М.: Наука, 1981. – 288с
4. Daubechies, Ten Lectures on Wavelets, CBMS-NSF Regional Series in Applied Mathematics, SIAM, Philadelphia, (1992).
5. Tarakanov A.O.,Skormin V.A., Sokolova S.P. Immunocomputing: principles and applications, Springer, 2003
6. Burnet F.M. The Clonal Selection Theory of Acquired Immunity. The University Press, Cambridge 1959.
7. De Castro, L. N. & Von Zuben, F. J. (2000a), “The Clonal Selection Algorithm with Engineering Applications”, submitted to GECCO’00.
8. Четырин С.П., Вилор М.Ю. Адаптивный нейросетевой компенсатор ошибок оператора-наводчика при визуальном слежении за целью//Збірник наукових праць Севастопольського військово-морського ордена Червоної зірки інститута ім. П.С.Нахімова. Випуск 1(9), 2006 р. С.151-157
9. Фефелов А.А., Литвиненко В.И. Горавский С.П. Построение и настройка вейвлет нейронных сетей при помощи искусственных иммунных систем// Інтелектуальні системи прийняття рішень та прикладні аспекти інформаційних технологій: Матеріали науково-практичної конференції, Том 5., с.77-80.
10. Bodyanskiy Ye., Lamonova N., Pliss I.,Vynokurova O. An adaptive learning algorithm for a wavelet neural network // Expert Systems. – 2005. – 22. - N. 5 – P.235-240.
11. Lekutai, G., Adaptive Self-Tuning Neuro Wavelet Network Controllers, PhD Thesis,  
1. Virginia Polytechnic Institute and State University, The Electrical Engineering Department, 1997.
12. Руденко О.Г., Бодянский Е.В. Основы теории искусственных нейронных сетей. — Харьков: ХЕЛЕТЕХ, 2002.