

логике А–В в рамках введенных аксиом нельзя построить систему с логическими и метрическими отрицаниями, которая бы не была противоречивой. В связи с этим вопрос о независимости исходных вероятностей фактов в гипотезе и ее отрицании остается открытым, то есть неопределенным. В рамках метрики и логики А–В можно задавать (определять) лишь конечное числовое значение отрицания первичной гипотезы, выраженное некоторым образом через метрическое значение исходной гипотезы.

Итак, подводя итоги вышесказанному, можно сделать следующие выводы.

1. В качестве операционного исчисления, используемого для формального описания логической зависимости гипотез от фактов и вычисления значений коэффициентов доверия в ЭС типа МУСИН, может быть применена двухзначная логика А–В с определенной на ней метрикой, причем двухполюсный граф гипотезы используется на стадии ее формирования.
2. На вид логической формы гипотезы и ее графа накладываются ограничения, вытекающие

из аксиом метрики произведения логики А–В и сводящиеся к запрету использования графов, не являющихся параллельно-последовательными по переменным  $A_i$  и  $B_j$ .

3. В рамках логики А–В и ее метрики не удается построить непротиворечивую систему с логическими и метрическими отрицаниями, поэтому вопрос о зависимости условных вероятностей в гипотезе и ее отрицании остается открытым.

## ЛИТЕРАТУРА

- [1] Дж. Э. Франклин и др. "Технология экспертных систем для военных применений: Избранные примеры.", статья в ТИИЭР, т. 76, № 10, октябрь 1988 г.
- [2] Зыков А.А. Гиперграфы. УМН. Т. XXIX. Выпуск 6/180. 1974.
- [3] Голиков В.П. Некоторые аналитические методы вычисления функции надежности сложных структур. Сб. Основные вопросы теории и практики надежности. М.: «Сов. радио», 1975.

## КОМПЛЕКСНАЯ МОДЕЛЬ "ГРАФОЛОГ" НА ОСНОВЕ ЭВОЛЮЦИОННО ОБУЧАЕМОЙ НЕЙРОННОЙ СЕТИ

Е.Г. Кочергов

Научно-исследовательский институт проблем криминологии, криминалистики и судебных экспертиз (НИИ ПККиСЭ), ул. Гвардейская, 7, Минск, 220035, БЕЛАРУСЬ, тел. (37517) 223-95-54, 206-59-72, ekochoergov@yahoo.com

### АННОТАЦИЯ

В статье рассматривается комплексная модель "Графолог" на основе эволюционно обучаемой нейронной сети. Данная модель предназначена для проведения автоматизированной психодиагностики по почерку. Автором предлагается новый эволюционный алгоритм формирования и обучения нейронной сети. Приведены результаты экспериментального применения построенной модели для двух психодиагностических методик.

### 1. ВВЕДЕНИЕ

Применение биометрических технологий, а именно совокупности методов и средств анализа признаков человека, присущих ему как биологическому объекту, сегодня вышло за рамки традиционных для них сфер (судебная экспертиза, медицина, психология) и востребовано в

различных компонентах технических, информационных и социотехнических систем [1, 2].

Большинство биометрических технологий предполагают непосредственный контакт с человеком, требуют применения дорогостоящего специального оборудования и специальных технических и организационных мер, поэтому сфера и использования сегодня весьма ограничена. Исследование почерка, напротив, допускает использование в качестве исходных данных письменных документов (или фрагментов документов), созданных человеком для любых целей, в том числе не связанных, например, с идентификацией.

Исследования автора, проводимые во взаимодействии с ведущими экспертами-почерковедами НИИ ПККиСЭ в 1992-2001 гг., на основе тщательного сопоставления анализируемых экспертами свойств почерка и признаков, которые возможно получить из статического изображения текста методами обработки и анализа

изображений позволили выделить систему из порядка 80 характеристик почерка, которые, с одной стороны, стабильно выделяются программой, а с другой стороны, устойчиво коррелируют с индивидуальными признаками людей. Сформулировать в явном виде причинно-следственные связи, приводящие к такой корреляции, на данном этапе не удастся, но их наличие подтверждается комплексом экспериментов, результатами тестирования и опытной эксплуатации созданных автором программных средств.

## 2. ОСНОВНЫЕ ЦЕЛИ ИССЛЕДОВАНИЯ И РЕШАЕМЫЕ ЗАДАЧИ

Необходимость автоматизации почерковедческих исследований продиктована, в первую очередь, расширением сфер их применения и вызвана следующими основными причинами:

- традиционная (“ручная”) почерковедческая экспертиза выполняется высококвалифицированными специалистами, что невозможно обеспечить для многих новых применений данной технологии;
- ручная экспертиза требует больших затрат времени, что не позволяет использовать ее для решения оперативных задач.

Основной целью проводимого исследования является автоматизация анализа почерка, позволяющая существенно ускорить этот анализ, а также сделать его доступным для более широкого применения за счет снижения требований к квалификации эксперта.

Описание почерка как объекта исследования системой признаков [3] дало возможность сформулировать задачи идентификации личности и психологической диагностики в терминах задач принятия решений и прогнозирования и выделить класс методов и стратегий, потенциально пригодных для их решения.

В данной статье рассматривается предложенный автором подход к решению одной из задач автоматизированного исследования почерка, а именно задача психологической диагностики по почерку.

## 3. ОПИСАНИЕ КОМПЛЕКСНОЙ МОДЕЛИ “ГРАФОЛОГ”

Научная идея автора заключается в компьютерном моделировании действий эксперта-графолога при решении задачи составления психологического портрета индивида на основе анализа его почерка. С этой целью предлагается комплексная модель “Графолог” (Рис. 1), ко-

торая органично объединяет все компоненты, необходимые для решения задачи автоматизированного психологического тестирования по почерку. Автоматизированное психологическое тестирование по почерку с использованием данной модели состоит из следующих этапов:

- сбор информации;
- обучение;
- непосредственно диагностика (функционирование в рабочем режиме).

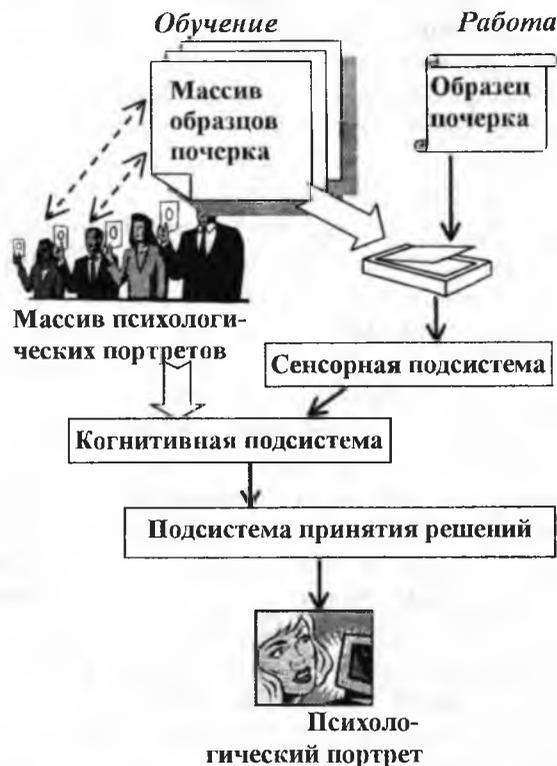


Рисунок 1. Комплексная модель графолога для автоматического решения задачи психологического тестирования по почерку

Этап сбора информации является необходимым для любого графологического исследования. Для этого осуществляется психологическое тестирование большой группы людей. Одновременно у каждого тестируемого берется образец почерка. Полученные таким образом данные составляют обучающую выборку.

Этап обучения графолога (в нашем случае – компьютерной модели “Графолог”) имеет целью выявить корреляции между признаками почерка, которые графолог может выделить из рукописного текста и психологическими характеристиками. В предлагаемом подходе сенсорная подсистема строит модель почерка [3] на основе изображения рукописного текста, оценивает для каждого образца обучающей выбор-

ки признаки почерка, и затем на основе сопоставления этих моделей с парными психологическими портретами когнитивная подсистема формирует и обучает нейронную сеть. В этом процессе эволюционно формируется структура многослойной нейронной сети, т.е. состав нейронных слоев и связи между ними, а также весовые коэффициенты связей между нейронами.

В следующем разделе подробно рассматриваются предложенные новые алгоритмы построения и обучения когнитивной подсистемы. Более подробную информацию об используемой сенсорной подсистеме и подсистеме принятия решений можно найти в [4].

Этап функционирования системы, обеспечивающий графологическое исследование почерка индивида с целью прогнозирования его психологических свойств заключается в следующем. Образец почерка тестируемого вводится с помощью сканера с бумажного листа в компьютер. Сенсорная подсистема выполняет обработку изображения и выделяет признаки почерка. Затем подсистема принятия решений строит психологический портрет.

Таким образом, предлагаемая модель психологического тестирования реализует подход, главная идея которого заключается в компьютерном моделировании естественных биологических структур и процессов. Главным «действующим лицом» является здесь эволюционно формируемая и обучаемая нейронная сеть. Автор не ставит цель выявить и формализовать в явном виде связь между почерком и психологическими свойствами человека, эта связь неявно выражается в структуре нейронной сети, соединениях нейронов и параметрах этих соединений.

Одним из следствий этого является своего рода «технологическая универсальность» предлагаемой модели. Как отмечалось в [5], в традиционной графологии существует множество методик, причем многие из них реализуют разные, ортогональные подходы, работая как бы в разных измерениях. Чтобы адекватно воплотить эти методики в автоматизированных системах, необходимы разные способы формализации данных и разные математические методы. Конечно, предлагаемый подход не претендует на то, чтобы одним способом реализовать все существующие методики – ориентация на определенную методику может потребовать некоторых изменений в алгоритме обучения нейронной сети или затронуть другие компоненты модели. Но единство общего метода открывает новые возможности для объединения

различных методик, их взаимообогащения и суммирования достоинств.

#### **4. ПРЕДПОСЫЛКИ РАЗРАБОТКИ ЭВОЛЮЦИОННЫХ АЛГОРИТМОВ ФОРМИРОВАНИЯ И ОБУЧЕНИЯ КОГНИТИВНОЙ ПОДСИСТЕМЫ**

В данном разделе рассмотрим некоторые предпосылки, предопределившие необходимость разработки автором собственного алгоритма формирования и обучения когнитивной подсистемы – многослойной нейронной сети.

Следует отметить, что класс нейронных сетей (многослойные, а не самоорганизующиеся карты, например) для использования в когнитивной подсистеме выбран автором априорно, исходя из соображений универсальности решаемой задачи. При этом процесс создания когнитивной подсистемы на основе многослойной нейронной сети имеет две составляющие: формирование структуры и собственно обучение, под которым понимается определение весовых коэффициентов связей между нейронами.

К настоящему времени для указанного класса нейронных сетей известны различные подходы к решению задач формирования структуры и обучения сети. При этом, не претендуя на всеобъемлющий охват данного вопроса, автор выделяет следующие основные тенденции:

- определение структуры сети производится эвристически (человеком или алгоритмом) [6];
- выбор оптимальной структуры из класса возможных выполняется при помощи эволюционного (генетического) алгоритма [7];
- весовые коэффициенты связей между нейронами определяются при помощи детерминистического градиентного алгоритма [6];
- весовые коэффициенты связей между нейронами определяются при помощи эволюционного либо стохастического алгоритма [7].

Следует отметить, что в соответствии с известными данными [7] каждое из перечисленных направлений характеризуется большим ростом вычислительных затрат при увеличении размеров сети. При этом для наиболее перспективного направления, с точки зрения «технологичности» решения сложных прикладных задач, указанный рост затрат проявляется особенно резко. Здесь имеется ввиду ситуация когда и структура сети, и весовые коэффициенты определяются при помощи генетического, либо в более общем случае эволюционного алгоритма.

Компромиссным решением указанной проблемы может считаться алгоритм Ивахненко

для нейронной сети с активными нейронами [8], где эволюционным методом группового учета аргументов (МГУА) формируется структура сети, а весовые коэффициенты вычисляются при помощи метода наименьших квадратов (МНК). Данный алгоритм имеет рекордно низкие в своем классе вычислительные затраты, однако рассчитан на сеть из нейронов, не содержащих нелинейной функции на выходе. При этом общеизвестны принципиальные недостатки сетей с такого рода нейронами, проявляющиеся в общем случае в неспособности решения некоторых простейших задач [9].

Таким образом, основной предпосылкой, разработки нового эволюционного алгоритма обучения многослойной нейронной сети явилась необходимость удовлетворения двух противоречивых условий:

- обучение нейронной сети большого размера<sup>1</sup>;
- использование эволюционных алгоритмов формирования и обучения сети.

Основная идея автора заключается, с одной стороны, в формировании структуры нейронной сети в соответствии с эволюционными принципами (внешнее дополнение, свобода выбора решений), и, с другой стороны, в определении весовых коэффициентов связей нейронов при помощи генетического алгоритма. При этом используются нейроны с традиционной нелинейной выходной функцией, а весовые коэффициенты вычисляются при помощи ранее разработанного автором вещественнозначного генетического алгоритма. В работе [10] показано, что предложенный автором генетический алгоритм для оптимизации функций вещественных аргументов имеет значительно меньшие вычислительные затраты, по сравнению с известными, за счет повышения направленности поиска.

На основании вышеизложенного автором сформулирован приводимый в следующем разделе эволюционный алгоритм формирования структуры многослойной нейронной сети.

## 5. ОПИСАНИЕ ПРЕДЛОЖЕННОГО ЭВОЛЮЦИОННОГО АЛГОРИТМА ФОРМИРОВАНИЯ СТРУКТУРЫ МНОГОСЛОЙНОЙ НЕЙРОННОЙ СЕТИ

В работе одного из классиков теории генетических алгоритмов Де Янга [11] приводятся следующие шаги для получения алгоритма,

специализированного для решения конкретной задачи:

- выбор некоторого представления для хромосом – рассматриваемых решений задачи в виде строки, дерева и т.д.;
- выбор или разработка операторов, которые формируют новые решения на основе имеющихся, так, чтобы наилучшим образом учесть особенности пространства поиска;
- выбор подходящего объема и структуры популяции, под которой понимается совокупность одновременно исследуемых хромосом;
- отбор хромосом для выживания и/или скрещивания на основе их «пригодности» (например, по значению целевой функции);
- экспериментальное определение соответствующих значений параметров, чтобы обеспечить сходимость процедуры поиска в важных областях пространства, избегая при этом сходимости к локальным оптимумам.

Определим основные понятия и характеристики предложенного алгоритма в соответствии с приведенными выше рекомендациями.

*Определение 1.* Хромосомы 0-го поколения представляют собой входные переменные решаемой задачи.

*Определение 2.* Хромосомы 1-го поколения представляют собой один нейрон с традиционной сигмоидной нелинейной функцией, с двумя или большим количеством входов и одним выходом. На входы хромосом 1-го поколения поступают входные переменные решаемой задачи.

*Определение 3.* Под хромосомой  $k$ -того поколения понимается нейронная сеть, состоящая из  $k$  слоев нейронов и содержащая один нейрон в выходном слое. На входы хромосом  $k$ -того поколения поступают выходы хромосом  $k-1$ -го поколения.

Рис. 2 иллюстрирует *определения 1-3*. Нейроны на данном рисунке показаны схематично в виде совокупности сумматора и нелинейной функции.

*Определение 4.* Под операцией скрещивания хромосом  $k$ -того поколения понимается объединение выходов случайным образом отобранных  $m$  ( $m > 1$ ) хромосом (т.е. нейронных сетей, см. определение 3) при помощи нейрона  $k+1$ -го слоя с образованием в результате хромосомы  $k+1$  поколения.

*Определение 5.* Под операцией мутации хромосомы  $k$ -того поколения понимается добавление на вход случайным образом выбранного нейрона  $k-1$ -го слоя связи с выходом случайным образом выбранного нейрона  $k-2$ -го слоя. Другими словами мутация приводит к

<sup>1</sup> Необходимый размер нейронной сети, как правило, сопоставим со сложностью решаемой задачи.

образованию случайных связей между нейронами ранее обученных соседних слоев сети.

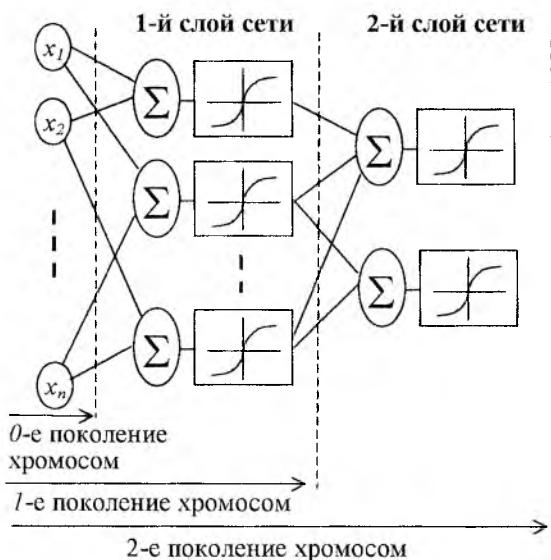


Рисунок 2. Представление многослойной нейронной сети в виде поколений хромосом

Если не придерживаться жестко концепции многослойной нейронной сети, которая во многом предопределена использованным для обучения алгоритмом обратного распространения ошибки [6], то *определение 5* может быть расширено в смысле возможности возникновения случайной связи не только между соседними слоями. В частности при наличии таких связей со входными переменными получаем некий аналог “протекции переменных” используемой в МГУА [12]. Следует отметить, что разработанный автором генетический алгоритм оптимизации функций вещественных аргументов [10] пригоден для определения весовых коэффициентов связей сети, как в случае жесткого следования концепции многослойной нейронной сети, так и в случае обсуждаемого возможного выхода за ее пределы.

*Определение 6.* Под значением функции приспособленности (*fitness function*) понимается оценка успешности решения хромосомой поставленной задачи – прогнозирования соответствующего психологического свойства личности на основе вектора входных переменных – признаков почерка. В качестве такой оценки, как и в традиционной (неграфологической) психодиагностике, используется коэффициент корреляции прогнозируемой переменной с реальными данными на контрольной выборке. *Контрольная выборка* – это независимый набор пар “психологический портрет – образец почерка”, который неизвестен на этапе обучения.

Введенные выше *определения 1-6* позволяют изложить эволюционный алгоритм формирования структуры многослойной нейронной сети в следующем виде.

1. Формируется *начальная* популяция хромосом 0-го поколения, согласно *определению 1*. Начальная популяция обозначается *текущей*.
2. Над хромосомами текущей популяции выполняется операция скрещивания согласно *определению 4*, в результате чего образуется *новая* популяция следующего поколения. Размер новой популяции больше текущей.
3. Над хромосомами новой популяции выполняется операция мутации согласно *определению 5*.
4. Производится обучение хромосом (вычисление весовых коэффициентов связей) новой популяции, которое рассматривается как решение при помощи вещественнозначного генетического алгоритма [10] задачи максимизации коэффициента корреляции прогнозируемой переменной с реальными данными на *обучающей* выборке.
5. Вычисляется значение функции приспособленности для хромосом новой популяции согласно *определению 6*. Следует отметить, что в отличие от шага 4 вычисление значения соответствующего коэффициента корреляции выполняется на *контрольной* выборке.
6. Выполняется отбор наилучших по значению функции приспособленности хромосом новой популяции, размер которой при этом уменьшается.
7. Если среднее либо максимальное значение функции приспособленности в новой выборке больше, чем в текущей, новая выборка обозначается *текущей* и происходит переход к шагу 2. В противном случае работа алгоритма завершается. Найденное решение – хромосома с максимальным значением функции приспособленности.

В следующем разделе рассматриваются результаты практического использования предложенного алгоритма в составе комплексной модели “Графолог”.

## 6. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТАЛЬНОЙ ОЦЕНКИ КОМПЛЕКСНОЙ МОДЕЛИ “ГРАФОЛОГ”

Проведенные автором экспериментальные исследования главным образом сконцентрированы вокруг экспериментальной проверки оправданности построения когнитивной подсистемы на основе эволюционно обучаемой ней-

ронной сети. При этом очевидно, приходится оценивать тот или иной вариант построения данной подсистемы по результатам работы модели “Графолог” в целом. Как уже отмечалось в предыдущем разделе в качестве такой оценки выступает общепринятый в психодиагностике коэффициент корреляции прогнозируемого (диагностируемого) на контрольной выборке психологического свойства по отношению к реальным данным (обозначается –  $R_{контр}$ ). При проведении исследования автором рассматривались следующие варианты построения когнитивной подсистемы:

- модель на основе пошаговой (*stepwise*) множественной линейной регрессии (ПЛР);
- нелинейная регрессионная модель на основе МГУА [12];
- нейросетевая модель с алгоритмом обучения обратным распространением ошибки (ВР) [6];
- нейросетевая модель с предложенным алгоритмом (ЭА);

В Табл. 1 и 2 приводятся результаты, полученные по двум психодиагностическим методикам Кеттела<sup>2</sup> и Русалова соответственно при одинаковом наборе входных переменных и одинаковых размерах обучающей и контрольной выборок. Прочерком обозначается отсутствие значимой корреляции для данного размера выборки.

Анализируя полученные результаты, следует учитывать, что в психодиагностика приемлемой считается методика, обеспечивающая  $R_{контр}$  в диапазоне 0,6..0,8. С этой точки зрения предложенный подход представляется перспективным.

Таблица 1. Оценка использования модели “Графолог” для психодиагностики по методике Кеттела

Психологическое свойство	$R_{контр}$			
	ПЛР	МГУА	ВР	ЭА
S1	0,420	0,491	0,431	0,640
S2	0,201	0,314	0,207	0,397
S3	–	0,163	–	0,296
S4	–	0,278	–	–
S5	–	0,382	–	0,375

<sup>2</sup> Автор не использует непосредственно 16 психологических свойств методики Кеттела, а набор из более устойчивых 5 факторов, полученных при помощи факторного анализа.

Таблица 2. Оценка использования модели “Графолог” для психодиагностики по методике Русалова

Психологическое свойство	$R_{контр}$			
	ПЛР	МГУА	ВР	ЭА
R	0,231	0,384	0,181	0,392
SR	–	0,325	–	0,403
P	0,345	0,407	–	0,528
SP	0,454	0,513	0,232	0,596
T	–	–	–	–
ST	0,198	0,367	0,168	–
M	0,204	0,336	0,206	–
SM	0,187	0,345	0,192	0,360

### 7. ЗАКЛЮЧЕНИЕ

При проведении дальнейших исследований автор намерен подробно изучить характеристики предложенного алгоритма по отношению к известным эволюционным и генетическим алгоритмам аналогичного назначения при решении различных прикладных задач.

Автор выражает благодарность и признательность к.т.н. Чеушеву В.А. за помощь и плодотворные дискуссии в рамках темы данной статьи.

### ЛИТЕРАТУРА

- [1]. Курбацкий А.Н. Автоматизация обработки документов. – Мн.: БГУ, 1999. 220 с.
- [2]. Shmerko V., Perkowski M., Dueck G., Rogers W., Yanushkevich S. Bio-Technologies in Computing: The Promises and the Reality // Proc. Int. Conf. on Computational Intelligence and Multimedia Applications, Australia. 1998. –P. 396-409.
- [3]. Кочергов Е.Г. Принцип автоматизированного извлечения признаков почерка // Вопросы криминологии, криминалистики и судебной экспертизы. Научное издание, Выпуск 15, Минск, 2000.
- [4]. Kochergov E., Zaitseva E., Strechen N., Stankevich Yu. Automated Design System of Person Psychological Portrait due to Handwriting Proc. of IFAC/IFIP Conference on Management and Control of Production and Logistics, – Campinas: SP, Brazil. – 1997. P. 726-730.
- [5]. Cohen F., Bradley N. Graphology Books - Indications for co-ordinated research and teaching in Western Europe, The Graphologist, Issue 62, 1999.
- [6]. Rumelhart D.E., Hinton G.E., Williams R.J. Learning internal representation by error propagation // Parallel Distributed Processing. – Cambridge, 1986.
- [7]. Kitano H. Empirical studies on the speed of convergence of neural network training using genetic algorithms // Proc. of the Eight Nat. Conf. on AI. – 1990, P. 789-795.

- [8]. Ivakhnenko A.G., Ivakhnenko G.A., Muller J.-A. Self-organization of Neural Networks with Active Neurons // Pattern Recognition and Image Analysis. – 1995. Vol. 4, № 2. P.185-196.
- [9]. Минский М. Л., Пейперт С. Перцептроны. – М. Мир. – 1971.
- [10]. Kochergov E. Using the Genetic Algorithm and Neural Network to solve the Person Identification Problem // Proc. of the Third Nordic Workshop on genetic Algorithms and their Applications, Finland. – 1997. – P.163-171.
- [11]. De Jong K. Evolutionary Computation: Recent Development and Open Issues // Proceedings of the First International Conference on Evolutionary Computation and Its Applications. – 1996. P. 7-17.
- [12]. Ивахненко А.Г. Долгосрочное прогнозирование и управление сложными системами. – Киев: «Техника». 1975. – 312 с.

## КОНСТРУКТИВНАЯ МЕТОДИКА СРАВНЕНИЯ НЕЧЕТКИХ ЧИСЕЛ И ЕЕ ПРИМЕНЕНИЕ В ЗАДАЧАХ ОПТИМИЗАЦИИ

П.В.Севастьянов<sup>1</sup>, А.В.Венберг<sup>2</sup>

<sup>1</sup> – Institute of Math. & Comp. Sci., Technical University of Czestochowa, Dabrowskiego st. 73, 42-201 Czestochowa, POLAND, tel/fax (1048+34) 3250331, sevast@k2.pcz.czes.pl

<sup>2</sup> – Кафедра «Экономическая информатика», Могилевский государственный технический университет, пр. Мира, 43, Могилев, 212005, БЕЛАРУСЬ, тел. (375+0222) 22-58-59, venberg@tut.by

### АННОТАЦИЯ

Одной из проблем, возникающих при моделировании и оптимизации в условиях неопределенности исходных данных является необходимость сравнения математических объектов, являющихся нечеткими числами. Характерным примером является задача оптимизации при нечеткой целевой функции. Для решения проблемы авторами разработана конструктивная методика сравнения нечетких интервалов, расширяющая возможности существующего аппарата нечетко-интервальной математики. Эффективность методики иллюстрируется примерами решения задач оптимизации.

### 1. ПРОБЛЕМА УЧЕТА НЕОПРЕДЕЛЕННОСТИ

При моделировании реальных объектов и процессов неизбежно присутствуют параметры, которые в силу своей природы не могут быть описаны четкими числами. К таким параметрам относятся данные, полученные при натурных испытаниях, подверженные колебаниям в результате нестабильности, характеризующие слабо изученные явления и объекты и т.д. В связи с этим возникает проблема учета объективно существующей неопределенности исходных данных, игнорирование которой зачастую приводит к результатам расчетов весьма далеким от реальности, что делает их не применимыми на практике.

Обычно при расчетах недостаточно точно известные параметры просто заменяются их средними значениями. Однако при таком под-

ходе происходит потеря весьма полезной информации. Получив на выходе конкретное число, которое является, предположительно, некоторым средним (наиболее вероятным) значением исследуемого параметра, мы абсолютно ничего не можем сказать о возможных пределах варьирования результата.

Часто задача усложняется наличием неопределенностей различных типов и информативности: часть параметров представлены в виде частотных распределений, для других параметров известны лишь диапазоны их возможных и наиболее вероятных значений.

В связи с этим, возникла необходимость разработки специальных методик, предназначенных для учета неопределенностей различных типов и информативности и позволяющих свободно оперировать с нечеткими данными.

### 2. ВЫБОР СПОСОБА УЧЕТА НЕОПРЕДЕЛЕННОСТИ ИСХОДНЫХ ДАННЫХ

В настоящее время можно выделить четыре способа учета неопределенности исходных данных:

- метод имитационного моделирования;
- оперирование с частотными распределениями;
- интервальный подход;
- нечетко-интервальный подход.

Метод имитационного моделирования как способ учета неопределенности исходных данных имеет ряд недостатков, среди которых можно выделить следующие: