



Запорізький національний технічний університет

## **Радіоелектроніка, інформатика, управління**

Науковий журнал

Виходить чотири рази на рік

№ 3(38) 2016

Заснований у січні 1999 року.

Засновник і видавець – Запорізький національний технічний університет.

ISSN 1607-3274 (друкований), ISSN 2313-688X (електронний).

Запоріжжя

ЗНТУ

2016

Запорожский национальный технический университет

## **Радиоэлектроника, информатика, управление**

Научный журнал

Выходит четыре раза в год

№ 3(38) 2016

Основан в январе 1999 года.

Основатель и издатель – Запорожский национальный технический университет.

ISSN 1607-3274 (печатный), ISSN 2313-688X (электронный).

Запорожье

ЗНТУ

2016

Zaporizhzhya National Technical University

## **Radio Electronics, Computer Science, Control**

The scientific journal

Published four times per year

№3(38) 2016

Founded in January 1999.

Founder and publisher – Zaporizhzhya National Technical University.

ISSN 1607-3274 (print), ISSN 2313-688X (on-line).

Zaporizhzhya

ZNTU

2016

**Науковий журнал «Радіоелектроніка, інформатика, управління»** (скорочена назва – РІУ) видається Запорізьким національним технічним університетом (ЗНТУ) з 1999 р. періодичністю чотири номери на рік.

Зареєстрований Державним комітетом інформаційної політики, телебачення та радіомовлення 29.01.2003 р. Свідцтво про державну реєстрацію друкованого засобу масової інформації серія КВ №6904.

ISSN 1607-3274 (друкований), ISSN 2313-688X (електронний).

Наказом Міністерства освіти і науки України № 1328 від 21.12.2015 р. «Про затвердження рішень Атестаційної колегії Міністерства щодо діяльності спеціалізованих вчених рад від 15 грудня 2015 року» **журнал включений до переліку наукових фахових видань України**, в яких можуть публікуватися результати дисертаційних робіт на здобуття наукових ступенів доктора і кандидата фізико-математичних та технічних наук.

В журналі безкоштовно публікуються наукові статті англійською, російською та українською мовами.

**Правила оформлення статей** подано на сайті: <http://ric.zntu.edu.ua/information/authors>.

Журнал забезпечує **безкоштовний відкритий он-лайн доступ** до повнотекстових публікацій.

Журнал дозволяє авторам мати авторські права і зберігати права на видання без обмежень. Журнал дозволяє користувачам читати, завантажувати, копіювати, поширювати, друкувати, шукати або посилатися на повні тексти своїх статей. Журнал дозволяє повторне використання його вмісту у відповідності з СС ліцензією СС-BY.

Опублікованими статтям присвоюється унікальний ідентифікатор цифрового об'єкта DOI.

**Журнал реферується та індексується** у провідних міжнародних та національних реферативних журналах і наукометричних базах даних, а також розміщується у цифрових архівах та бібліотеках з безкоштовним доступом у режимі on-line (у т. ч. DOAJ, DOI, CrossRef, EBSCO, eLibrary.ru / РИНЦ, Google Scholar, Index Copernicus, INSPEC, ISSN, Ulrich's Periodicals Directory, WorldCat, ВІНІТІ, Джерело), повний перелік яких подано на сайті: <http://ric.zntu.edu.ua/about/editorialPolicies#custom-0>.

**Журнал розповсюджується** за Каталогом періодичних видань України (передплатний індекс – 22914).

**Тематика журналу** містить: радіофізику, мікро-, нано- і радіоелектроніку, апаратне і програмне забезпечення комп'ютерної техніки, комп'ютерні мережі і телекомунікації, теорію алгоритмів і програмування, оптимізацію і дослідження операцій, міжмашинну і людино-машинну взаємодію, математичне і комп'ютерне моделювання, обробку даних і сигналів, управління в технічних системах, штучний інтелект, включаючи системи, засновані на знаннях, і експертні системи, інтелектуальний аналіз даних, розпізнавання образів, штучні нейронні і нейро-нечіткі мережі, нечітку логіку, колективний інтелект і мультиагентні системи, гібридні системи.

Усі статті, пропоновані до публікації, одержують **об'єктивний розгляд**, що оцінюється за суттю без урахування раси, статі, віросповідання, етнічного походження, громадянства або політичної філософії автора(ів).

Усі статті проходять двоступінчасте закрите (анонімне для автора) **рецензування** штатними редакторами і незалежними рецензентами – провідними вченими за профілем журналу.

#### РЕДАКЦІЙНА КОЛЕГІЯ

**Головний редактор** – Погосов В. В., д-р фіз.-мат. наук, Україна

**Заст. головного редактора** – Субботін С. О., д-р. техн. наук, Україна

**Члени редколегії:**

Андролідакіс Й., д-р філософії, Греція

Безрук В. М., д-р техн. наук, Україна

Бодяньський С. В., д-р техн. наук, Україна, редактор розділу з управління

Васильєв С. М., д-р фіз.-мат. наук, академік РАН, Росія

Гімплевич Ю. Б., д-р техн. наук, Україна

Горбань О. М., д-р фіз.-мат. наук, Великобританія

Дробахін О. О., д-р фіз.-мат. наук, Україна

Зайцева О. М., канд. фіз.-мат. наук, Словаччина

Камеяма М., д-р техн. наук, Японія

Карпуков Л. М., д-р техн. наук, Україна

Корніч Г. В., д-р фіз.-мат. наук, Україна, редактор розділу з радіофізики

Кулік А. С., д-р техн. наук, Україна

Лебедев Д. В., д-р техн. наук, Україна, редактор розділу з управління

Левашенко В. Г., канд. фіз.-мат. наук, Словаччина

Лиснянський А., канд. техн. наук, Ізраїль

Марковська-Качмар У., д-р наук, Польща

Олещук В. О., канд. фіз.-мат. наук, Норвегія, редактор розділу з радіоелектроніки

Онуфрієнко В. М., д-р фіз.-мат. наук, Україна

Папшицький М., д-р філософії, Польща

Піза Д. М., д-р техн. наук, Україна

Рубель О. І., канд. техн. наук, Канада

Хаханов В. І., д-р техн. наук, Україна, редактор розділу з інформатики

Шарпанських О. А., д-р філософії, Нідерланди, редактор розділу з інформатики

Рекомендовано до видання вченою радою ЗНТУ, протокол № 2 від 03.10.2016.

Журнал зверстаний редакційно-видавничим відділом ЗНТУ.

**Веб-сайт журналу:** <http://ric.zntu.edu.ua>.

**Адреса редакції:** Редакція журналу «РІУ», Запорізький національний технічний університет, вул. Жуковського, 64, м. Запоріжжя, 69063, Україна.

Тел: (061) 769-82-96 – редакційно-видавничий відділ

Факс: (061) 764-46-62

E-mail: [rvv@zntu.edu.ua](mailto:rvv@zntu.edu.ua)

**Научный журнал «Радиоэлектроника, информатика, управление»** (сокращенное название – РИУ) издается Запорожским национальным техническим университетом (ЗНТУ) с 1999 г. периодичностью четыре номера в год.

Зарегистрирован Государственным комитетом информационной политики, телевидения и радиовещания 29.01.2003 г. (Свидетельство о государственной регистрации печатного средства массовой информации серия КВ №6904).

**ISSN 1607-3274** (печатный), **ISSN 2313-688X** (электронный).

Приказом Министерства образования и науки Украины № 1328 от 21.12.2015 г. «Об утверждении решений Аттестационной коллегии Министерства относительно деятельности специализированных ученых советов от 15 декабря 2015 года» **журнал включен в перечень научных профессиональных изданий Украины**, в которых могут публиковаться результаты диссертационных работ на соискание ученых степеней доктора и кандидата физико-математических и технических наук.

В журнале бесплатно публикуются научные статьи на английском, русском и украинском языках.

**Правила оформления статей** представлены на сайте: <http://ric.zntu.edu.ua/information/authors>.

Журнал обеспечивает **бесплатный открытый он-лайн доступ** к полнотекстовым публикациям. Журнал разрешает авторам иметь авторские права и сохранять права на издание без ограничений. Журнал разрешает пользователям читать, загружать, копировать, распространять, печатать, искать или ссылаться на полные тексты своих статей. Журнал разрешает повторное использование его содержания в соответствии с СС лицензией СС-BY.

Опубликованным статьям присваивается уникальный идентификатор цифрового объекта DOI.

**Журнал реферирован и индексируется** в ведущих международных и национальных реферативных журналах и наукометрических базах данных, а также размещается в цифровых архивах и библиотеках с бесплатным доступом on-line (в т. ч. DOAJ, DOI, CrossRef, EBSCO, eLibrary.ru / РИНЦ, Google Scholar, Index Copernicus, INSPEC, ISSN, Ulrich's Periodicals Directory, WorldCat, ВИНТИ, Джэрло), полный перечень которых представлен на сайте: <http://ric.zntu.edu.ua/about/editorialPolicies#custom-0>.

**Журнал распространяется** по Каталогу периодических изданий Украины (подписной индекс – 22914).

**Тематика журнала** включает: радиофизику, микро-, нано- и радиоэлектронику, аппаратное и программное обеспечение компьютерной техники, компьютерные сети и телекоммуникации, теорию алгоритмов и программирования, оптимизацию и исследование операций, межмашинное и человеко-машинное взаимодействие, математическое и компьютерное моделирование, обработку данных и сигналов, управление в технических системах, искусственный интеллект, включая системы, основанные на знаниях, и экспертные системы, интеллектуальный анализ данных, распознавание образов, искусственные нейронные и нейро-нечеткие сети, нечеткую логику, коллективный интеллект и мультиагентные системы, гибридные системы.

Все статьи, предлагаемые к публикации, получают **объективное рассмотрение**, которое оценивается по существу без учета расы, пола, вероисповедания, этнического происхождения, гражданства или политической философии автора(ов).

Все статьи проходят двухступенчатое закрытое (анонимное для автора) **рецензирование** штатными редакторами и независимыми рецензентами – ведущими учеными по профилю журнала.

## РЕДАКЦИОННАЯ КОЛЛЕГИЯ

**Главный редактор** – Погосов В. В., д-р физ.-мат. наук, Украина

**Зам. главного редактора** – Субботин С. А., д-р техн. наук, Украина

**Члены редколлегии:**

Андроидакис И., д-р философии, Греция

Безрук В. М., д-р техн. наук, Украина

Бодянский Е. В., д-р техн. наук, Украина, редактор раздела по управлению

Васильев С. Н., д-р физ.-мат. наук, академик РАН, Россия

Гимпилевич Ю. Б., д-р техн. наук, Украина

Горбань А. Н., д-р физ.-мат. наук, Великобритания

Дробахин О. О., д-р физ.-мат. наук, Украина

Зайцева Е. Н., канд. физ.-мат. наук, Словакия

Камеяма М., д-р техн. наук, Япония

Карпуков Л. М., д-р техн. наук, Украина

Корнич Г. В., д-р физ.-мат. наук, Украина, редактор раздела по радиофизике

Кулик А. С., д-р техн. наук, Украина

Лебедев Д. В., д-р техн. наук, Украина, редактор раздела по управлению

Левашенко В. Г., канд. физ.-мат. наук, Словакия

Лиснянский А., канд. техн. наук, Израиль

Марковска-Качмар У., д-р наук, Польша

Олещук В. А., канд. физ.-мат. наук, Норвегия, редактор радиоэлектроники

Онуфриенко В. М., д-р физ.-мат. наук, Украина

Папшицкий М., д-р философии, Польша

Пиза Д. М., д-р техн. наук, Украина

Рубель О. И., канд. техн. наук, Канада

Хаханов В. И., д-р техн. наук, Украина, редактор раздела по информатике

Шарпанских А. А., доктор философии, Нидерланды – редактор раздела по информатике

Рекомендовано к изданию ученым советом ЗНТУ, протокол № 2 от 03.10.2016.

Журнал сверстан редакционно-издательским отделом ЗНТУ.

**Веб-сайт журнала:** <http://ric.zntu.edu.ua>.

**Адрес редакции:** Редакция журнала «РИУ», Запорожский национальный технический университет, ул. Жуковского, 64, г. Запорожье, 69063, Украина.

Тел.: +38-061-769-82-96 – редакционно-издательский отдел

Факс: (061) 764-46-62

E-mail: [rvv@zntu.edu.ua](mailto:rvv@zntu.edu.ua)

© Запорожский национальный технический университет, 2016

**The scientific journal «Radio Electronics, Computer Science, Control»** is published by the Zaporizhzhya National Technical University (ZNTU). since 1999 with periodicity four numbers per year.

The journal is registered by the State Committee for information policy, television and radio broadcasting of Ukraine in 29.01.2003. The journal has a State Registration Certificate of printed mass media (series KB №6904).

**ISSN 1607-3274** (print), **ISSN 2313-688X** (on-line).

By the Order of the Ministry of Education and Science of Ukraine from 21.12.2015 № 1328 “On approval of the decision of the Certifying Collegium of the Ministry on the activities of the specialized scientific councils dated 15 December 2015” **journal is included in the list of scientific specialized periodicals of Ukraine**, where the results of dissertations for Doctor of Science and Doctor of Philosophy in Mathematics and Technical Sciences may be published.

The journal publishes scientific articles in English, Russian, and Ukrainian free of charge.

The **article formatting rules** are presented on the site: <http://ric.zntu.edu.ua/information/authors>.

The journal provides policy of **on-line open (free of charge) access** for full-text publications. The journal allow the authors to hold the copyright without restrictions and to retain publishing rights without restrictions. The journal allow readers to read, download, copy, distribute, print, search, or link to the full texts of its articles. The journal allow reuse and remixing of its content, in accordance with a CC license CC-BY.

Published articles have a unique digital object identifier (DOI).

**The journal is abstracted and indexed** in leading international and national abstracting journals and scientometric databases, and also placed to the digital archives and libraries with a free on-line access (including DOAJ, DOI, CrossRef, EBSCO, eLibrary.ru / РИИЦ, Google Scholar, Index Copernicus, INSPEC, ISSN, Ulrich's Periodicals Directory, WorldCat, VINITI (All-Russian Institute of scientific and technical information), Djerelo), full list of which is presented on the site: <http://ric.zntu.edu.ua/about/editorialPolicies#custom-0>.

**The journal is distributed:** by the Catalogue of Ukrainian periodicals (the catalog number is 22914).

**The journal scope:** radio physics, micro-, nano- and radio electronics, computer hardware and software, computer networks and telecommunications, algorithm and programming theory, optimization and operations research, machine-machine and man-machine interfacing, mathematical modeling and computer simulation, data and signal processing, control in technical systems, artificial intelligence, including knowledge-based and expert systems, data mining, pattern recognition, artificial neural and neuro-fuzzy networks, fuzzy logics, swarm intelligence and multiagent systems, hybrid systems.

All articles proposed for publication receive an **objective review** that evaluates substantially without regard to race, sex, religion, ethnic origin, nationality, or political philosophy of the author(s).

All articles undergo a two-stage **blind peer review** by the editorial staff and independent reviewers – the leading scientists on the profile of the journal.

## EDITORIAL BOARD

**Editor-in-Chief:** V. V. Pogosov, Doctor of Science in Physics and Mathematics, Ukraine

**Deputy Editor-in-Chief:** S. A. Subbotin, Doctor of Science in Engineering, Ukraine

### Members of Editorial Board:

I. Androulidakis, Ph. D, Greece

V. M. Bezruk, Doctor of Science in Engineering, Ukraine

Ye. V. Bodyanskiy, Doctor of Science in Engineering, Ukraine, Control section editor

O. O. Drobakhin, Doctor of Science in Physics and Mathematics

Yu. B. Gimpilevich, Doctor of Science in Engineering, Ukraine

A. N. Gorban, Doctor of Science in Physics and Mathematics, United Kingdom

V. I. Hahanov, Doctor of Science in Engineering, Ukraine, Computer Science section editor

M. Kameyama, Doctor of Science, Japan

L. M. Karpukov, Doctor of Science in Engineering, Ukraine

G. V. Kornich, Doctor of Science in Physics and Mathematics, Ukraine, Radio Physics section editor

A. S. Kulik, Doctor of Science in Engineering, Ukraine

D. V. Lebedev, Doctor of Science in Engineering, Ukraine, Control section editor

V. G. Levashenko, Ph.D, Slovakia

A. Lisnianski, Ph.D, Israel

U. Markowska-Kaczmar, Doctor of Science, Poland

V. A. Oleshchuk, Ph.D in Physics and Mathematics, Norway, Radio Electronics section editor

V. M. Onufrienko, Doctor of Science in Physics and Mathematics, Ukraine

M. Paprzycki, Ph.D, Poland

D. M. Piza, Doctor of Science in Engineering, Ukraine

O. I. Rubel, Ph.D, Canada

A. A. Sharpanskykh, Ph.D, Netherlands, Computer Science section editor

S. N. Vassilyev, Doctor of Science in Physics and Mathematics, Academician of Russian Academy of Sciences, Russia

E. N. Zaitseva, Ph.D, Slovakia

Recommended for publication by the Academic Council of ZNTU, protocol № 2 dated 03.10.2016.

The journal is imposed by the editorial-publishing department of ZNTU.

**The journal web-site** is <http://ric.zntu.edu.ua>.

**The address of the editorial office:** Editorial office of the journal «Radio Electronics, Computer Science, Control», Zaporizhzhia National Technical University, Zhukovskiy street, 64, Zaporizhzhya, 69063, Ukraine.

Tel.: +38-061-769-82-96 – the editorial-publishing department.

Fax: +38-061-764-46-62

E-mail: [rvv@zntu.edu.ua](mailto:rvv@zntu.edu.ua)

## ЗМІСТ

<b>РАДІОЕЛЕКТРОНІКА ТА ТЕЛЕКОМУНІКАЦІЇ.....</b>	<b>7</b>
<i>Курапов С. В., Чеченя В. С.</i> МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ПРОВЕДЕНИЯ СОЕДИНЕНИЙ В ОБЛАСТИ VGA КОМПОНЕНТ.....	7
<i>Пица Д. М., Лаврентьев В. Н., Семенов Д. С.</i> МЕТОД ФОРМИРОВАНИЯ КЛАССИФИЦИРОВАННОЙ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ АВТОКОМПЕНСАТОРА ПОМЕХ ПРИ ВРЕМЯ-ПРОСТРАНСТВЕННОЙ ФИЛЬТРАЦИИ СИГНАЛОВ.....	18
<b>МАТЕМАТИЧНЕ ТА КОМП'ЮТЕРНЕ МОДЕЛЮВАННЯ.....</b>	<b>23</b>
<i>Шергин В. Л.</i> СВЯЗЬ МЕЖДУ ПАРАМЕТРАМИ САМОПОДОБИЯ, УСТОЙЧИВОСТИ И ДОЛГОСРОЧНОЙ ЗАВИСИМОСТИ ПРИРАЩЕНИЙ ФРАКТАЛЬНОГО ДВИЖЕНИЯ ЛЕВИ.....	23
<b>НЕЙРОІНФОРМАТИКА ТА ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ.....</b>	<b>30</b>
<i>Бодянський Є. В., Дейнеко А. О., Куценко Я. В.</i> ПОСЛІДОВНЕ НЕЧІТКЕ КЛАСТЕРУВАННЯ НА ОСНОВІ НЕЙРО-ФАЗЗИ ПІДХОДУ.....	30
<i>Гороховатский В. А., Гороховатский А. В., Берестовский А. Е.</i> СТРУКТУРНОЕ РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ С ПРИМЕНЕНИЕМ МОДЕЛЕЙ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ И САМООРГАНИЗАЦИИ ПРИЗНАКОВ.....	39
<i>Субботин С. А.</i> ПОСТРОЕНИЕ ПОЛНОСТЬЮ ОПРЕДЕЛЕННЫХ НЕЙРО-НЕЧЕТКИХ СЕТЕЙ С РЕГУЛЯРНЫМ РАЗБИЕНИЕМ ПРОСТРАНСТВА ПРИЗНАКОВ НА ОСНОВЕ ВЫБОРОК БОЛЬШОГО ОБЪЕМА.....	47
<b>ПРОГРЕСИВНІ ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ.....</b>	<b>54</b>
<i>Бісікало О. В., Висоцька В. А.</i> ЗАСТОСУВАННЯ МЕТОДУ СИНТАКСИЧНОГО АНАЛІЗУ РЕЧЕНЬ ДЛЯ ВИЗНАЧЕННЯ КЛЮЧОВИХ СЛІВ УКРАЇНОМОВНОГО ТЕКСТУ.....	54
<i>Ковнир А. Э., Степаненко К. Э., Ильяшенко М. Б.</i> УВЕЛИЧЕНИЕ ДОСТОВЕРНОСТИ ВОССТАНОВЛЕНИЯ РАСФОКУСИРОВАННЫХ ИЗОБРАЖЕНИЙ ЗА СЧЕТ ИСПРАВЛЕНИЯ ОШИБКИ ОКРУГЛЕНИЯ.....	66
<i>Литвин В. В., Демчук А. Б., Оборська О. В.</i> МАТЕМАТИЧНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ПОДАННЯ ВІДЕОКОНТЕНТУ ДЛЯ ОСІБ З ВАДАМИ ЗОРУ.....	73
<i>Фауре Э. В., Швыдкий В. В., Щерба В. А.</i> КОМБИНИРОВАННОЕ ФАКТОРИАЛЬНОЕ КОДИРОВАНИЕ И ЕГО СВОЙСТВА.....	80
<i>Федушко С. С.</i> РОЗРОБЛЕННЯ СИСТЕМИ ВЕРИФІКАЦІЇ СОЦІАЛЬНО-ДЕМОГРАФІЧНИХ ДАНИХ УЧАСНИКА ВІРТУАЛЬНОЇ СПІЛЬНОТИ.....	87
<b>УПРАВЛІННЯ У ТЕХНІЧНИХ СИСТЕМАХ.....</b>	<b>93</b>
<i>Авдеев В. В.</i> ТОЧНІСТЬ І ЗАПАС СТІЙКОСТІ СИСТЕМИ СТАБІЛІЗАЦІЇ ОБЕРТАЛЬНОГО РУХУ РАКЕТИ.....	93
<i>Мамедов К. Ш., Мамедова А. Г.</i> ПОНЯТИЯ СУБОПТИМИСТИЧЕСКОГО И СУБПЕССИМИСТИЧЕСКОГО РЕШЕНИЙ И ПОСТРОЕНИЕ ИХ В ИНТЕРВАЛЬНОЙ ЗАДАЧЕ БУЛЕВОГО ПРОГРАММИРОВАНИЯ.....	99

---

# CONTENTS

<b>RADIO ELECTRONICS AND TELECOMMUNICATIONS.....</b>	<b>7</b>
<i>Kurapov S. V., Chechenja V. S.</i> MATHEMATICAL MODEL OF CONNECTION TRACING IN THE AREA OF BGA COMPONENTS.....	7
<i>Piza D., Lavrentiev V., Semenov D.</i> METHOD OF FORMING OF THE CLASSIFIED TRAINING SAMPLE FOR AUTOMATIC CANCELLER OF THE INTERFERENCES WHEN USING TIME-SPACE FILTERING OF SIGNALS.....	18
<b>MATHEMATICAL AND COMPUTER MODELLING.....</b>	<b>23</b>
<i>Shergin V. L.</i> RELATIONSHIP BETWEEN THE PARAMETERS OF SELF-SIMILARITY, STABILITY AND LONG-RANGE DEPENDENCY OF FRACTAL LEVÝ MOTION.....	23
<b>NEUROINFORMATICS AND INTELLIGENT SYSTEMS.....</b>	<b>30</b>
<i>Bodyanskiy Ye. V., Deineko A. O., Kutsenko Ya. V.</i> SEQUENTIAL FUZZY CLUSTERING BASED ON NEURO-FUZZY APPROACH.....	30
<i>Gorokhovatsky V. A., Gorokhovatskyi A. V., Berestovskiy A. E.</i> STRUCTURAL IDENTIFICATION OF IMAGE RECOGNITION BASED WITH MODELS OF INTELLECTUAL SELF-ORGANIZATION FEATURES.....	39
<i>Subbotin S. A.</i> BUILDING A FULLY DEFINED NEURO-FUZZY NETWORK WITH A REGULAR PARTITION OF A FEATURE SPACE BASED ON LARGE SAMPLE.....	47
<b>PROGRESSIVE INFORMATION TECHNOLOGIES.....</b>	<b>54</b>
<i>Bisikalo O. V., Vysotska V. A.</i> SENTENCE SYNTACTIC ANALYSIS APPLICATION TO KEYWORDS IDENTIFICATION UKRAINIAN TEXTS.....	54
<i>Kovnir A. E., Stepanenko K. E., Ilyahsneko M. B.</i> DEFOCUSED IMAGE RESTORATION CONFIDENCE INCREASING BY IMPROVING ROUNDING ERRORS CORRECTIONS.....	66
<i>Lytvyn V. V., Demchyk A. B., Oborska O. V.</i> MATHEMATICAL AND SOFTWARE SUBMISSION VIDEO CONTENT FOR VISUALLY IMPAIRED PEOPLE.....	73
<i>Faure E. V., Shvydkyi V. V., Shcherba V. O.</i> COMBINED FACTORIAL CODING AND ITS PROPERTIES.....	80
<i>Fedushko S. S.</i> DEVELOPMENT OF VERIFICATION SYSTEM OF SOCIO-DEMOGRAPHIC DATA OF VIRTUAL COMMUNITY MEMBER.....	87
<b>CONTROL IN TECHNICAL SYSTEMS.....</b>	<b>93</b>
<i>Avdejev V. V.</i> ACCURACY AND STABILITY FACTOR OF A ROCKET ROTATION STABILIZATION SYSTEM.....	93
<i>Mamedov K. Sh., Mamedova A. H.</i> DEFINITIONS OF SUBOPTIMISTIC AND SUBPessimistic SOLUTIONS AND THEIR CONSTRUCTION IN THE INTERVAL BOOLEAN PROGRAMMING PROBLEM.....	99

# РАДИОЕЛЕКТРОНИКА ТА ТЕЛЕКОМУНІКАЦІЇ

# РАДИОЕЛЕКТРОНИКА И ТЕЛЕКОММУНИКАЦИИ

# RADIO ELECTRONICS AND TELECOMMUNICATIONS

УДК 519.172

Курапов С. В.<sup>1</sup>, Чеченя В. С.<sup>2</sup>

<sup>1</sup>Канд. физ.-мат. наук, доцент Запорожского национального университета, Запорожье, Украина  
<sup>2</sup>Аспирант Запорожского национального университета, Запорожье, Украина

## МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ПРОВЕДЕНИЯ СОЕДИНЕНИЙ В ОБЛАСТИ BGA КОМПОНЕНТ

В статье рассмотрена проблема проектирования радиоэлектронной аппаратуры плоских конструктивов в области BGA. Показано, что трассировка плоских конструктивов в области BGA не дает требуемых результатов из-за отсутствия универсальной математической модели и зачастую осуществляется вручную. Поэтому в данной работе представлена универсальная математическая модель, основанная на теоретико-множественном описании расположения соединений между контактами BGA компонент для вывода их на периферию, что очень важно при проектировании плоских конструктивов. Также в работе приведено детальное описание общего рисунка схемы для схем с матричным расположением контактов, таких как BGA, как для непересекающихся соединений, так и описание расположения пересекающихся соединений. Предложен метод определения пересечения проводников для расположения пересекающихся соединений. Показано, что кортеж элементов схемы может быть использован для описания проведения соединений, проверки загрузки макродискретов и определения пересечения проводников. Предложенная универсальная математическая модель может снизить трудоемкость и время проектирования топологии плоских конструктивов, а также может быть использована для разработки топологий микроэлектромеханических структур различного назначения.

**Ключевые слова:** BGA компонент, схема, рисунок, макродискрет, кортеж, множество, канал.

### НОМЕНКЛАТУРА

МПУ – многозондовое подключающее устройство;

ЭК – электронные компоненты.

$a, b, c, d, e, f, \dots$  – линии уровня;

$M_{1\dots} = \langle b_1, b_2, b_3, a_1 \rangle$  – макродискрет;

$L_{b\dots} = \langle b_1, b_2, a_1, b_3 \rangle$  – кортеж;

$q$  – ребра;

$s$  – след соединения;

$w$  – топометрические линии;

$\text{pr}(\ )$  – проекции соединений;

$V_{1\dots} = \{M_1, M_4, M_9, M_{16}\}$  – вертикальные каналы;

$\Gamma_{1\dots} = \{M_1, M_2, M_5, M_{10}\}$  – горизонтальные каналы;

### ВВЕДЕНИЕ

Современной базой проектирования плоских конструктивов являются системы автоматизации проектирования. Существующие системы, такие как ACCEL EDA P-CAD 2002, Protel DXP, OrCAD 9.2, Allegro, SPECCTRA, TOPOR, осуществляют множество функций. Это и размещение компонент на поверхности плоского конструктива, проведение соединений, расчет помехоустойчивости и т.д.

Несмотря на очевидный прогресс в технологии автоматической трассировки плоских конструктивов, по отзывам самих конструкторов [1], в лучшем случае приходится вносить значительные коррективы в полученное автоматизированное решение вручную, в худшем – и вовсе разводит плату вручную. Это вызвано тем, что в основу применяемых математических методов моделирования положены только геометрические свойства, с полным игнорированием топологических свойств проведения соединений [2]. Так как в основе большинства алгоритмов автотрассировки лежит геометрический алгоритм С.Ли. В современных системах САПР в библиотеку компонентов заложены только геометрические параметры. В то время как такое чисто топологическое свойство как пересечение соединений учитывается в недостаточной степени. Все это привело к тому, что современные математические модели в системах проектирования плоских конструктивов можно отнести к последовательным алгоритмам. Для таких систем характерен слепой неуправляемый поиск, с огромными вычислительными временными затра-

тами. Мало того, в результате получается только один вариант решения, причем, как правило, далекий от оптимального. При таком подходе вопросы многовариантного решения задачи даже не затрагиваются. Все это говорит о необходимости смены парадигмы методов математического моделирования [2,3].

Что касается математических моделей для описания соединений с BGA компонентами, то их просто не существует. Авторами предлагается серия статей описания и применения разработанной математической модели для построения рисунка соединений плоского конструктива с BGA компонентами. В следующих работах будут представлены методы и алгоритмы проведения соединений плоских конструктивов в области BGA компонент с пересечением и без пересечения проводников с различными стратегиями разводки на основе предложенной математической модели.

## 1 ПОСТАНОВКА ЗАДАЧИ

Целью данной работы является создание математической модели для описания рисунка схемы проведения соединений в области BGA компонент, которая будет основана на теоретико-множественных методах дискретной математики. Приводится подробное описание общего рисунка, как для непересекающихся соединений, так и описание расположения пересекающихся соединений. Приведено описание топологического способа определения пересечения соединений.

## 2 ОБЗОР ЛИТЕРАТУРЫ

*Плоским конструктивом* будем называть техническое устройство (конструкцию), где непересекающиеся соединения между элементами устройства и сами элементы расположены в параллельных (эквидистантных) плоскостях. Это могут быть печатные платы, интегральные микросхемы, БИС, СБИС и т.д.

Характерной особенностью современных сложных электронных устройств является применение микросхем большой и сверхбольшой степени интеграции. Это и чипы программируемой логики, и однокристалльные процессоры, и множество других устройств. По мере усложнения микросхем растет и число выводов, как информационных, так и питания. Обычные типы корпусов для выводного монтажа, например QFP или SOP, уже не могут обеспечить должное количество паяных соединений и их качественный монтаж в связи со значительным увеличением линейных размеров и массы корпуса. Поэтому особенно большое распространение получили компоненты в корпусах BGA [4]. Микросхемы в корпусе BGA относительно недороги и отличаются малыми размерами [5].

Но, несмотря на популярность применения, трассировка печатных плат с участием корпусов BGA проблематична. Современные программные средства не в состоянии справиться с поставленной задачей, сложности возникают из-за большого количества слоев трассируемых соединений, малых значений толщины проводников и расстояний между ними, специфики межслойных соединений и ряда других факторов [6].

Проблему проведения соединений частично решают шаблоны трассировки, но как бы ни было эффектив-

ным использование шаблонов [7], процесс трассировки не обходится без проведения соединений вручную, а в некоторых случаях и вовсе весь процесс трассировки осуществляется вручную.

## 3 МАТЕРИАЛЫ И МЕТОДЫ

### 3.1 Модель корпуса BGA

Математическую модель для BGA компонент и проведения соединений можно представить в виде циклического фрагмента с контактами, расположенными по концентрическим окружностям  $a, b, c, d, e, f \dots$  (рис. 1, 2).

Рассмотрим компонент BGA для корпуса с 324 матрично-расположенными контактами, которые представлены в 18-ти горизонтальных и вертикальных рядах. Такое расположение контактов определяет симметрию относительно центра. Симметрия расположения позволяет рассматривать контакты и проведение соединений только в одной четверти математической модели корпуса (рис. 3 а, б).




Рисунок 1 – Фрагмент корпуса на 36 выводов и проведение соединений




Рисунок 2 – Топологическая модель корпуса на 36 выводов и проведение соединений



Математическая модель представляет собой совокупность концентрических окружностей, количество которых определяется расположением рядов матрично-расположенных контактов (рис. 2). Концентрические окружности можно характеризовать как проведенные линии от центра симметрии и называть их *линиями уровня* (рис. 3), обозначаемые латинскими буквами  $a, b, c, d, e, f, \dots$ , количество которых определяется количеством рядов матрично-расположенных контактов (рис. 4).

Например, линия уровня В – это множество  $B = \{b_1, b_2, b_3\}$ , линия уровня С – это множество  $C = \{c_1, c_2, c_3, c_4, c_5\}$  (рис. 4).

Парная совокупность линий уровня образует центральные каналы, как часть ограниченного пространства  $R^2$ . Центральные каналы будем обозначать двумя буквами, например,  $de$  – это канал, ограниченный линией уровня  $d$  и линией уровня  $e$  (рис. 3).

Каждый центральный канал состоит из макродискретов.

**Определение 1.** *Макродискрет* представляет собой четырехугольник, в углах которого расположены четыре контакта (рис. 5).





Рисунок 3 – Верхняя левая часть корпуса BGA с 324 матрично-расположенными контактами

По расположению в центральных каналах различают диагональные макродискреты, макродискреты ниже диагонали и макродискреты выше диагонали.

Множество макродискретов будем нумеровать от центра на периферию (рис. 6).

Подмножества макродискретов образуют вертикальные и горизонтальные каналы рис. 7 а, б.

Принадлежность контактов в макродискретах всегда можно определить из рис. 6.




Рисунок 4 – Математическая модель корпуса BGA для проведения соединений




Рисунок 5 – Макродискрет  $M_1 = \langle b_1, b_2, b_3, a_1 \rangle$






Рисунок 6 – Нумерация макродискретов



а



б

Рисунок 7 – Горизонтальные и вертикальные каналы

Правила формирования макродискретов для горизонтальных и вертикальных каналов представлены в нижеследующих прямоугольных матрицах:

Горизонтальные каналы

M <sub>1</sub>									
M <sub>2</sub>	M <sub>5</sub>	M <sub>4</sub>							
M <sub>3</sub>	M <sub>6</sub>	M <sub>8</sub>	M <sub>9</sub>						
M <sub>10</sub>	M <sub>11</sub>	M <sub>12</sub>	M <sub>13</sub>	M <sub>14</sub>	M <sub>15</sub>	M <sub>16</sub>			
M <sub>17</sub>	M <sub>18</sub>	M <sub>19</sub>	M <sub>20</sub>	M <sub>21</sub>	M <sub>22</sub>	M <sub>23</sub>	M <sub>24</sub>	M <sub>25</sub>	
...	...	...	...	...	...	...	...	...	...

Заполняем строки матрицы номерами макродискретов соответствующих центральных каналов. В первую строку помещаем макродискретов первого центрально-

го канала – M<sub>1</sub>. Во вторую строку последовательно слева направо помещаем макродискретов второго центрального канала – M<sub>2</sub>, M<sub>3</sub>, M<sub>4</sub>, и так далее. Исходя из определенного количества макродискретов в канале, начиная с правой верхней заполненной клетки, отсчитываем заданное количество макродискретов справа налево и сверху вниз, исключая макродискретов предыдущего уровня. Например, первый горизонтальный канал состоит из 5-ти макродискретов: M<sub>1</sub>, M<sub>2</sub>, M<sub>5</sub>, M<sub>10</sub>, M<sub>17</sub>. Второй горизонтальный канал состоит из 5-ти макродискретов: M<sub>4</sub>, M<sub>3</sub>, M<sub>6</sub>, M<sub>11</sub>, M<sub>18</sub>. Третий горизонтальный канал состоит из 5-ти макродискретов: M<sub>9</sub>, M<sub>8</sub>, M<sub>7</sub>, M<sub>12</sub>, M<sub>19</sub> и так далее.

Вертикальные каналы

M <sub>1</sub>									
M <sub>2</sub>	M <sub>5</sub>	M <sub>2</sub>							
M <sub>6</sub>	M <sub>8</sub>	M <sub>6</sub>	M <sub>5</sub>						
M <sub>16</sub>	M <sub>15</sub>	M <sub>14</sub>	M <sub>13</sub>	M <sub>12</sub>	M <sub>11</sub>	M <sub>10</sub>			
M <sub>25</sub>	M <sub>24</sub>	M <sub>23</sub>	M <sub>22</sub>	M <sub>21</sub>	M <sub>20</sub>	M <sub>19</sub>	M <sub>18</sub>	M <sub>17</sub>	
...	...	...	...	...	...	...	...	...	...

Правило объединения макродискретов в вертикальные каналы отличается только первоначальным заполнением строк номерами макродискретов центральных каналов в обратном порядке. То есть, в первую строку помещаем макродискретов первого центрального канала в обратном порядке – M<sub>4</sub>, M<sub>3</sub>, M<sub>2</sub>, и так далее.

### 3.2 Рисунок соединений между контактами корпуса BGA

**Определение 2.** Общим рисунком будем называть рисунок подключенных соединений ко всем задействованным контактам, с учетом всех конструктивно-технологических ограничений без учета их распределения по слоям.

Общий рисунок бывает двух видов. Первый вид – это рисунок с непересекающимися соединениями (см. рис. 8), а второй вид – это общий рисунок с пересекающимися соединениями (см. рис. 9, а, б, в, г).




Рисунок 8 – Общий рисунок с непересекающимися соединениями




Рисунок 9 – Общий рисунок с пересекающимися соединениями

**Определение 3.** Линии, соединяющие контакты макро-дискрета, будем называть *топометрическими линиями*.

**Определение 4.** Пересечение топометрической линии и соединения будем называть *следом соединения*.

Общий рисунок с непересекающимися соединениями описывается кортежем [8–10], состоящим из последовательного перечисления контактов и следов соединений на самой периферийной линии. Например, для рисунка соединений, представленного на рис. 7:

$$L_e = \langle \mathbf{e}_1, \mathbf{d}_1, \mathbf{e}_2, \mathbf{c}_1, \mathbf{d}_2, \mathbf{e}_3, \mathbf{c}_2, \mathbf{e}_4, \mathbf{d}_3, \mathbf{b}_1, \mathbf{e}_5, \mathbf{c}_3, \mathbf{d}_4, \mathbf{b}_2, \mathbf{e}_6, \mathbf{a}_1, \mathbf{b}_3, \mathbf{d}_5, \mathbf{c}_4, \mathbf{e}_7, \mathbf{d}_6, \mathbf{c}_5, \mathbf{e}_8, \mathbf{d}_7, \mathbf{e}_9 \rangle.$$

Здесь контакты выделены жирным шрифтом, в отличие от следов соединений нижестоящих контактов.

Размещение контактов и следов соединений на линии следующего нижнего уровня описывается кортежем с удаленными контактами предыдущего верхнего уровня:

$$L_d = \langle \mathbf{d}_1, \mathbf{c}_1, \mathbf{d}_2, \mathbf{c}_2, \mathbf{d}_3, \mathbf{b}_1, \mathbf{c}_3, \mathbf{d}_4, \mathbf{b}_2, \mathbf{a}_1, \mathbf{b}_3, \mathbf{d}_5, \mathbf{c}_4, \mathbf{d}_6, \mathbf{c}_5, \mathbf{d}_7 \rangle;$$

$$L_c = \langle \mathbf{c}_1, \mathbf{c}_2, \mathbf{b}_1, \mathbf{c}_3, \mathbf{b}_2, \mathbf{a}_1, \mathbf{b}_3, \mathbf{c}_4, \mathbf{c}_5 \rangle;$$

$$L_b = \langle \mathbf{b}_1, \mathbf{b}_2, \mathbf{a}_1, \mathbf{b}_3 \rangle.$$

Описание общего рисунка с пересекающимися соединениями носит иной характер, здесь приходится описывать расположение контактов и следов соединений отдельно для каждой линии уровня. Для записи таких рисунков с пересекающимися соединениями приходится четко различать контакты и следы соединений, отмечать следы штрихом. Например, для рисунка соединений представленного на рис. 9а:

$$L_e = \langle \mathbf{e}_1, \mathbf{a}_1, \mathbf{b}_3, \mathbf{b}_2, \mathbf{e}_2, \mathbf{c}_5, \mathbf{c}_4, \mathbf{c}_3, \mathbf{c}_2, \mathbf{d}_1, \mathbf{c}_4, \mathbf{c}_1, \mathbf{b}_1, \mathbf{c}_5 \rangle;$$

$$L_d = \langle \mathbf{d}_1, \mathbf{a}_1, \mathbf{b}_3, \mathbf{b}_2, \mathbf{d}_2, \mathbf{c}_5, \mathbf{c}_4, \mathbf{c}_3, \mathbf{d}_3, \mathbf{d}_7, \mathbf{d}_6, \mathbf{d}_5, \mathbf{d}_4, \mathbf{d}_3, \mathbf{d}_2, \mathbf{d}_5, \mathbf{c}_2, \mathbf{d}_1, \mathbf{d}_6, \mathbf{c}_1, \mathbf{b}_1, \mathbf{d}_7 \rangle;$$

$$L_c = \langle \mathbf{c}_1, \mathbf{a}_1, \mathbf{b}_3, \mathbf{b}_2, \mathbf{c}_2, \mathbf{c}_5, \mathbf{c}_4, \mathbf{c}_3, \mathbf{c}_2, \mathbf{d}_1, \mathbf{c}_4, \mathbf{c}_1, \mathbf{b}_1, \mathbf{c}_5 \rangle;$$

$$L_b = \langle \mathbf{b}_1, \mathbf{a}_1, \mathbf{b}_3, \mathbf{b}_2, \mathbf{c}_1, \mathbf{b}_1, \mathbf{b}_3 \rangle.$$

Для рисунка соединений, представленного на рис. 9г:

$$L_e = \langle \mathbf{b}_2, \mathbf{c}_3, \mathbf{d}_4, \mathbf{e}_1, \mathbf{d}_1, \mathbf{c}_2, \mathbf{d}_3, \mathbf{e}_2, \mathbf{c}_1, \mathbf{d}_2, \mathbf{e}_3, \mathbf{b}_1, \mathbf{e}_4, \mathbf{e}_5, \mathbf{e}_6, \mathbf{b}_3, \mathbf{e}_7, \mathbf{d}_6, \mathbf{c}_5, \mathbf{e}_8, \mathbf{d}_5, \mathbf{c}_4, \mathbf{d}_7, \mathbf{e}_9, \mathbf{a}_1 \rangle;$$

$$L_d = \langle \mathbf{b}_2, \mathbf{c}_3, \mathbf{d}_1, \mathbf{c}_2, \mathbf{c}_1, \mathbf{d}_2, \mathbf{b}_1, \mathbf{d}_3, \mathbf{d}_4, \mathbf{d}_5, \mathbf{b}_3, \mathbf{d}_6, \mathbf{c}_4, \mathbf{c}_5, \mathbf{d}_7, \mathbf{a}_1 \rangle;$$

$$L_c = \langle \mathbf{b}_2, \mathbf{c}_1, \mathbf{b}_1, \mathbf{c}_2, \mathbf{c}_3, \mathbf{c}_4, \mathbf{b}_3, \mathbf{c}_5, \mathbf{a}_1 \rangle;$$

$$L_b = \langle \mathbf{b}_1, \mathbf{b}_2, \mathbf{b}_3, \mathbf{a}_1 \rangle.$$

### 3.3 Рисунок с непересекающимися соединениями

Для рисунка с непересекающимися соединениями размещение контактов и следов соединений можно вычислить, имея последовательность расположения контактов и следов соединений на самой верхней периферийной линии.

В свою очередь, линии уровня формируют содержимое диагональных каналов (рис. 10).

Представленная математическая модель позволяет определить загрузку макродискрета. Подсчет количества соединений в макродискрете в случае рисунка с непересекающимися соединениями можно получить следующим образом. Выбираем в макродискрете все номера контактов, например, в макродискрете  $M_7 = \langle d_3, d_4, d_5, c_3 \rangle$  для рис. 7. Затем в кортеже соединений выбираем номера контактов, начиная с  $d_3$  до следующего  $d_4$ . Вертикальной стороне макродискрета  $\langle d_3 - d_4 \rangle$  принадлежит след соединений  $\{b_1, c_3\}$  – линии уровня  $L_d = \langle d_1, c_1, d_2, c_2, d_3, b_1, c_3, d_4, b_2, a_1, b_3, d_5, c_4, d_6, c_5, d_7 \rangle$ . Горизонтальной стороне макродискрета  $\langle d_4 - d_5 \rangle$  принадлежит след соединений  $\{b_2, a_1, b_3\}$  – линии уровня  $L_d = \langle d_1, c_1, d_2, c_2, d_3, b_1, c_3, d_4, b_2, a_1, b_3, d_5, c_4, d_6, c_5, d_7 \rangle$ . Вертикальной стороне макродискрета  $\langle d_5 - c_3 \rangle$  принадлежит след соединений  $\{b_3, a_1, b_2\}$  – линии уровня  $L_d = \langle d_1, c_1, d_2, c_2, d_3, b_1, c_3, d_4, b_2, a_1, b_3, d_5, c_4, d_6, c_5, d_7 \rangle$ , определяемые в обратном направлении. И наконец, горизонтальной стороне макродискрета  $\langle d_5 - c_3 \rangle$  принадлежит след соединений  $\{b_1\}$  – линии уровня  $L_d = \langle d_1, c_1, d_2, c_2, d_3, b_1, c_3, d_4, b_2, a_1, b_3, d_5, c_4, d_6, c_5, d_7 \rangle$ . Множество соединений макродискрета  $M_7 = \{b_1, c_3, b_3, a_1, b_2\}$ . Количество соединений в макродискрете определяется как мощность множества. В данном случае мощность множества равна пяти. Данный процесс определения загрузки макродискрета можно изобразить диаграммой (рис. 11). Данное правило применимо для любого макродискрета.




Рисунок 10 – Формирование диагональных каналов

$\langle d_1, c_1, d_2, c_2, d_3, b_1, c_3, d_4, b_2, a_1, b_3, d_5, c_4, d_6, c_5, d_7 \rangle$



Рисунок 11 – Диаграмма определения проекций для сторон макродискрета  $M_7 = \langle d_3, d_4, d_5, c_3 \rangle$

### 3.4 Рисунок с пересекающимися соединениями

В случае рисунков с пересекающимися соединениями определение следов соединений для сторон макродискретов расположенных на линиях уровня не представляет особого труда. Куда проблематичнее становится определение пересечений соединений и топометрических линий между двумя ближайшими линиями уровня (рис. 12, 13).

Будем рассматривать горизонтальные и вертикальные топометрические линии.




Рисунок 12 – Диагональный канал




Рисунок 13 – Развернутый диагональный канал

В качестве примера рассмотрим диагональный канал, созданный линиями  $c$  и  $b$  на рис. 9а. Для определения пересечения соединений и топометрических линий приходится рассматривать диагональный канал как координатно-базисную систему и попарно определять пересечение соединений и топометрических линий, соответствующих сторонам макродискрета (рис. 14, контакты выделены более серым) [11].

Ребра координатно-базисной системы будем обозначать  $q$ , соединения будем обозначать  $s$ , топометрические линии –  $w$ . Определим проекции соединений и топометрических линий на координатно-базисную систему:

$$\begin{aligned} \text{pr}(w_1) &= \langle q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle; \\ \text{pr}(w_2) &= \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle; \\ \text{pr}(w_3) &= \langle q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle; \\ \text{pr}(w_4) &= \langle q_{16}, q_{17}, q_{18} \rangle; \\ \text{pr}(s_5) &= \langle q_1, q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19} \rangle; \\ \text{pr}(s_6) &= \langle q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19}, q_{20}, q_{21} \rangle; \\ \text{pr}(s_7) &= \\ &= \langle q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19}, q_{20} \rangle; \\ \text{pr}(s_8) &= \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10} \rangle; \\ \text{pr}(s_9) &= \langle q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle; \\ \text{pr}(s_{10}) &= \langle q_6, q_7, q_8, q_9 \rangle; \\ \text{pr}(s_{11}) &= \langle q_8, q_9, q_{10}, q_{11} \rangle; \end{aligned}$$





$$\begin{aligned} \cap \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10} \rangle &= \text{pr}(w_2) \cap \text{pr}(s_8) = \\ &= \langle q_9, q_{10} \rangle - \text{пересечение есть}; \\ \text{pr}(w_2) \cap \text{pr}(s_9) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle &- \\ - \text{pr}(w_2) \in \text{pr}(s_9) - \text{пересечения нет}; \\ \text{pr}(w_2) \cap \text{pr}(s_{10}) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_6, q_7, q_8, q_9 \rangle &= \text{pr}(w_2) \cap \text{pr}(s_{10}) = \langle q_9 \rangle - \text{пересе-} \\ &\text{чение есть}; \\ \text{pr}(w_2) \cap \text{pr}(s_{11}) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_8, q_9, q_{10}, q_{11} \rangle &= \text{pr}(w_2) \cap \text{pr}(s_{11}) = \langle q_9, q_{10}, q_{11} \rangle - \\ &\text{пересечение есть}; \\ \text{pr}(w_2) \cap \text{pr}(s_{12}) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_{13}, q_{14}, q_{15}, q_{16}, q_{17} \rangle &= \text{pr}(s_{12}) \in \text{pr}(w_2) - \text{пересече-} \\ &\text{ния нет}; \\ \text{pr}(w_2) \cap \text{pr}(s_{13}) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_{14}, q_{15}, q_{16} \rangle &= \text{pr}(s_{13}) \in \text{pr}(w_2) - \text{пересечения нет}; \\ \text{pr}(w_2) \cap \text{pr}(s_{14}) &= \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle \cap \\ \cap \langle q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14} \rangle &= \text{pr}(s_{14}) \cap \text{pr}(w_2) = \\ = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14} \rangle &- \text{пересечение есть}; \end{aligned}$$

$$\begin{aligned} \text{pr}(s_5) \cap \text{pr}(s_6) &= \\ = \langle q_1, q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19} \rangle \cap \\ \cap \langle q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19}, q_{20}, q_{21} \rangle &= \\ = \text{pr}(s_5) \cap \text{pr}(s_6) &= \\ = \langle q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19} \rangle &- \\ - \text{пересечение есть}; \\ \text{pr}(s_5) \cap \text{pr}(s_7) &= \\ = \langle q_1, q_2, q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19} \rangle \cap \\ \cap \langle q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19}, q_{20} \rangle &= \\ = \text{pr}(s_5) \cap \text{pr}(s_7) &= \\ = \langle q_3, q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18}, q_{19} \rangle &- \\ - \text{пересечение есть}; \end{aligned}$$

$$\begin{aligned} \text{pr}(s_8) \cap \text{pr}(s_9) &= \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11} \rangle \cap \\ \cap \langle q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14}, q_{15}, q_{16}, q_{17}, q_{18} \rangle &= \\ = \text{pr}(s_8) \cap \text{pr}(s_9) &= \\ = \langle q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11} \rangle &- \text{пересечение есть}; \\ \text{pr}(s_8) \cap \text{pr}(s_{10}) &= \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11} \rangle \cap \end{aligned}$$

$$\begin{aligned} \cap \langle q_6, q_7, q_8, q_9 \rangle &= \text{pr}(s_{10}) \in \text{pr}(s_8) - \text{пересечения нет}; \\ \text{pr}(s_8) \cap \text{pr}(s_{11}) &= \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11} \rangle \cap \\ \cap \langle q_6, q_7, q_8, q_9 \rangle &= \text{pr}(s_8) \cap \text{pr}(s_{11}) = \\ = \langle q_6, q_7, q_8, q_9 \rangle &- \text{пересечение есть}; \\ \text{pr}(s_8) \cap \text{pr}(s_{12}) &= \langle q_4, q_5, q_6, q_7, q_8, q_9, q_{10}, q_{11} \rangle \cap \\ \cap \langle q_{13}, q_{14}, q_{15}, q_{16}, q_{17} \rangle &= \emptyset - \text{пересечения нет}; \end{aligned}$$

$$\begin{aligned} \text{pr}(s_{12}) \cap \text{pr}(s_{13}) &= \langle q_{13}, q_{14}, q_{15}, q_{16}, q_{17} \rangle \cap \\ \cap \langle q_{14}, q_{15}, q_{16} \rangle &= \\ = \text{pr}(s_{13}) \in \text{pr}(s_{12}) &- \text{пересечения нет}; \end{aligned}$$

$$\begin{aligned} \text{pr}(s_{13}) \cap \text{pr}(s_{14}) &= \langle q_{14}, q_{15}, q_{16} \rangle \cap \\ \cap \langle q_7, q_8, q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14} \rangle &= \\ = \text{pr}(s_{13}) \cap \text{pr}(s_{14}) &= \langle q_{14} \rangle - \text{пересечение есть}. \end{aligned}$$

Рассмотрим вопрос последовательности пересечения топологических линий соединениями. С этой целью рассмотрим пересечение топологической линии  $s_2$ :

$$\text{pr}(w_2) \cap \text{pr}(s_8) = \langle q_9, q_{10} \rangle - \text{пересечение есть};$$

$$\text{pr}(w_2) \cap \text{pr}(s_{10}) = \langle q_9 \rangle - \text{пересечение есть};$$

$$\text{pr}(w_2) \cap \text{pr}(s_{11}) = \langle q_9, q_{10}, q_{11} \rangle - \text{пересечение есть};$$

$$\text{pr}(w_2) \cap \text{pr}(s_{14}) = \langle q_9, q_{10}, q_{11}, q_{12}, q_{13}, q_{14} \rangle - \text{пересе-} \\ \text{чение есть};$$

$$\text{pr}(s_8) \cap \text{pr}(s_{10}) = \emptyset - \text{пересечения нет};$$

$$\text{pr}(s_{11}) \cap \text{pr}(s_{14}) = \emptyset - \text{пересечения нет};$$

$$\text{pr}(s_8) \cap \text{pr}(s_{11}) = \langle q_8, q_9, q_{10} \rangle - \text{пересечение есть};$$

$$\text{pr}(s_8) \cap \text{pr}(s_{14}) = \langle q_7, q_8, q_9, q_{10} \rangle - \text{пересечение есть};$$

$$\text{pr}(s_{10}) \cap \text{pr}(s_{11}) = \langle q_8, q_9 \rangle - \text{пересечение есть};$$

$$\text{pr}(s_{10}) \cap \text{pr}(s_{14}) = \langle q_7, q_8, q_9 \rangle - \text{пересечение есть}.$$

Таким образом, на топологической линии  $\langle c_3, b_2 \rangle$  вначале располагается след от соединения  $s_8$  (с меньшей длиной проекций пересечения), затем след не пересекающегося с  $s_8$  соединения  $s_{10}$  (с большей длиной проекций пересечения). Что касается не пересекающихся между собой соединений  $s_{11}$  и  $s_{14}$ , вначале располагается след соединения  $s_{11}$ , а затем след соединения  $s_{14}$ . Данные следы соединений могут быть расположены в любом месте на топологической линии, но их порядок нарушать нельзя. Поэтому топологическая линия может характеризоваться разными записями, например:

$$\langle c_3, s_8(d_1), s_{10}(c_2), s_{11}(c_4), s_{14}(c_5), b_2 \rangle;$$

$$\text{или } \langle c_3, s_8(d_1), s_{11}(c_4), s_{10}(c_2), s_{14}(c_5), b_2 \rangle;$$

$$\text{или } \langle c_3, s_8(d_1), s_{11}(c_4), s_{14}(c_5), s_{10}(c_2), b_2 \rangle \text{ и т.д.}$$

После определения расположения следов соединений на топологических линиях определяется порядок проведения соединений в макродискретах, а также в горизонтальных и вертикальных каналах.

Опишем макродискрету как совокупность контактов и следов соединений:

$$\begin{aligned}
 M_1 &= \{ \langle b_1, a_1, b_3, c_1, b_2 \rangle, \langle b_2, c_1, b_1, b_3 \rangle, \langle b_3, a_1 \rangle, \langle a_1, b_1 \rangle \}; \\
 M_2 &= \{ \langle c_1, a_1, b_3, c_1, b_2, d_1, c_2 \rangle, \langle c_2, d_1, b_2 \rangle, \langle b_2, c_1, b_3, a_1, b_1 \rangle, \langle b_1, c_1 \rangle \}; \\
 M_3 &= \{ \langle c_2, c_5, c_4, c_3 \rangle, \langle c_3, c_2, d_1, c_4 \rangle, \langle c_4, c_5, b_2 \rangle, \langle b_2, d_1, c_2 \rangle \}; \\
 M_4 &= \{ \langle b_2, c_5, c_4 \rangle, \langle c_4, c_1, b_1, c_5 \rangle, \langle c_5, b_3 \rangle, \langle b_3, b_1, c_1, b_2 \rangle \}; \\
 M_5 &= \{ \langle d_1, a_1, b_3, b_2, d_2 \rangle, \langle d_2, c_2 \rangle, \langle c_2, d_1, b_2, b_3, a_1, c_1 \rangle, \langle c_1, d_1 \rangle \}; \\
 M_6 &= \{ \langle d_2, c_5, c_4, c_3, d_3 \rangle, \langle d_3, d_2, c_3 \rangle, \langle c_3, c_4, c_5, c_2 \rangle, \langle c_2, d_2 \rangle \}; \\
 M_7 &= \{ \langle d_3, d_7, d_6, d_5, d_4 \rangle, \langle d_4, d_3, d_2, d_5 \rangle, \langle d_5, d_6, d_7, c_3 \rangle, \langle c_3, d_2, d_3 \rangle \}; \\
 M_8 &= \{ \langle c_3, d_7, d_6, d_5 \rangle, \langle d_5, c_2, d_1, d_6 \rangle, \langle d_6, d_7, c_4 \rangle, \langle c_4, d_1, c_2, c_3 \rangle \}; \\
 M_9 &= \{ \langle c_4, d_7, d_6 \rangle, \langle d_6, c_1, b_1, d_7 \rangle, \langle d_7, c_5 \rangle, \langle c_5, b_1, c_1, c_4 \rangle \}; \\
 M_{10} &= \{ \langle e_1, a_1, b_3, b_2, e_2 \rangle, \langle e_2, d_2 \rangle, \langle d_2, b_2, b_3, a_1, d_1 \rangle, \langle d_1, e_1 \rangle \}; \\
 M_{11} &= \{ \langle e_2, c_5, c_4, c_3, e_3 \rangle, \langle e_3, d_3 \rangle, \langle d_3, c_3, c_4, c_5, d_2 \rangle, \langle d_2, e_2 \rangle \}; \\
 M_{12} &= \{ \langle e_3, d_7, d_6, d_5, e_4 \rangle, \langle e_4, e_3, d_4 \rangle, \langle d_4, d_5, d_6, d_7, d_3 \rangle, \langle d_3, e_3 \rangle \}; \\
 M_{13} &= \{ \langle e_4, d_4, e_9, e_8, e_5 \rangle, \langle e_5, e_4, e_3, e_6 \rangle, \langle e_6, e_8, e_9, d_4 \rangle, \langle d_4, e_3, e_4 \rangle \}; \\
 M_{14} &= \{ \langle d_4, e_9, e_8, e_6 \rangle, \langle e_6, d_3, d_2, e_7 \rangle, \langle e_7, e_8, e_9, d_5 \rangle, \langle d_5, d_2, d_3, d_4 \rangle \}; \\
 M_{15} &= \{ \langle d_5, e_9, e_8, e_7 \rangle, \langle e_7, c_2, d_1, e_8 \rangle, \langle e_8, e_9, d_6 \rangle, \langle d_6, d_1, c_1, d_5 \rangle \}; \\
 M_{16} &= \{ \langle d_6, e_9, e_8 \rangle, \langle e_8, c_1, b_1, e_9 \rangle, \langle e_9, d_7 \rangle, \langle d_7, b_1, c_1, d_6 \rangle \}.
 \end{aligned}$$

Запишем вертикальные каналы как множество макродискретов:

$$\begin{aligned}
 B_1 &= \{ M_1, M_4, M_9, M_{16} \} = \\
 & \langle b_1, a_1, b_3, c_1, b_2, c_5, c_4, d_7, d_6, e_9, e_8, c_1, b_1, e_9, d_7, c_5, b_3, a_1, b_1 \rangle; \\
 B_2 &= \{ M_2, M_3, M_8, M_{15} \} = \\
 & \langle c_1, a_1, b_3, b_2, c_2, c_5, c_4, c_3, d_7, d_6, d_5, e_9, e_8, e_7, c_2, d_1, e_8, e_9, d_6, d_7, c_4, c_5, b_2, c_1, b_3, \\
 & \quad a_1, b_1, c_1 \rangle; \\
 B_3 &= \{ M_5, M_6, M_7, M_{14} \} = \\
 & \langle d_1, a_1, b_3, b_2, d_2, c_5, c_4, c_3, d_3, d_7, d_6, d_5, d_4, e_9, e_8, e_6, d_3, d_2, e_7, e_8, \\
 & \quad e_9, d_5, d_6, d_7, c_3, c_4, c_5, c_2, d_1, b_2, b_3, a_1, c_1, d_1 \rangle; \\
 B_4 &= \{ M_{10}, M_{11}, M_{12}, M_{13} \} = \\
 & \langle e_1, a_1, b_3, b_2, e_2, c_5, c_4, c_3, e_3, d_7, d_6, d_5, e_4, d_4, e_9, e_8, e_5, e_4, e_3, \\
 & \quad e_6, e_8, e_9, d_4, d_5, d_6, d_7, d_3, c_3, c_4, c_5, d_2, b_2, b_3, a_1, d_1, e_1 \rangle.
 \end{aligned}$$

Запишем горизонтальные каналы как множество макродискретов:

$$\begin{aligned}
 \Gamma_1 &= \{ M_1, M_2, M_5, M_{10} \} = \\
 & \langle a_1, b_1, c_1, d_1, e_1, a_1, b_3, b_2, e_2, d_2, c_2, d_1, b_2, c_1, b_1, b_3, a_1 \rangle; \\
 \Gamma_2 &= \{ M_3, M_4, M_6, M_{11} \} = \\
 & \langle b_3, b_1, c_1, b_2, d_1, c_2, d_2, e_2, c_5, c_4, c_3, e_3, d_3, d_2, c_3, c_2, d_1, c_4, c_1, b_1, c_5, b_3 \rangle; \\
 \Gamma_3 &= \{ M_7, M_8, M_9, M_{12} \} = \\
 & \langle c_5, b_1, c_1, c_4, d_1, c_2, c_3, d_2, d_3, d_7, d_6, d_5, e_4, e_3, d_4, d_3, d_2, d_5, c_2, d_1, \\
 & \quad d_6, c_1, b_1, d_7, c_5 \rangle; \\
 \Gamma_4 &= \{ M_{13}, M_{14}, M_{15}, M_{16} \} = \\
 & \langle d_7, b_1, c_1, d_6, d_1, c_2, d_5, d_2, d_3, d_4, e_3, e_4, d_4, e_9, e_8, e_5, e_4, e_3, e_6, d_3, d_2, e_7, c_2, d_1, \\
 & \quad e_8, c_1, b_1, e_9, d_7 \rangle.
 \end{aligned}$$

#### 4 ЭКСПЕРИМЕНТЫ

Для проверки работы математической модели проведены расчеты для BGA компонент размером 18x18 контактов. Предложенная математическая модель была использована для разработки микроэлектромеханического многозондового подключающего устройства (МПУ), предназначенного для подключения электронных компонентов (ЭК) с матричными выводами шарикового типа (BGA/CSP) на операциях входного и функционального контроля к автоматизированным контролирующим комплексам или специализированным пультам контроля перед подачей ЭК на последующие операции сборки радиоэлектронных средств (блоков, модулей) [12].

В качестве объекта контроля была выбрана микросхема FG-320, характеризующаяся следующими параметрами:

- количество выводов 320 (18x18, без четырех выводов в центре);
- шаг размещения выводов – 1 мм;
- диаметр шарикового вывода – 600 мкм [12].

#### 5 РЕЗУЛЬТАТЫ

В результате эксперимента предложенный метод, основанный на применении теоретико-множественного описания, снизил трудоемкость и время проектирования топологии гибкого шлейфа МПУ (рис. 15), а также может быть использован для разработки топологий микроэлектромеханических структур различного назначения [13].




Рисунок 15 – Топология прижимающей пластины

## 6 ОБСУЖДЕНИЕ

Предложенный метод формирования рисунка схемы по сравнению с метрическими методами [5, 6, 14] обеспечивает более качественные результаты проведения соединений, сокращая при этом время проектирования.

Также, в отличие от существующих методов, предложенный метод автоматически определяет пересечение проводников, загрузку макродискретов и расслоение схемы, то есть еще до этапа трассировки можно проводить оптимизацию будущего решения.

## ВЫВОДЫ

Предложенная математическая модель позволяет описать рисунок проведения соединений между контактами BGA компонент теоретико-множественными методами, без конкретной прорисовки на плоскости. Данная модель позволяет хранить, описывать и видоизменять информацию общего рисунка соединений, как в случае проведения непересекающихся соединений, так и при проведении соединений с пересечением, используя явления симметрии.

Предложенная математическая модель применялась при разработке микроэлектромеханического многозондового подключающего устройства [12], предназначенного для подключения электронных компонентов (ЭК) с матричными выводами шарикового типа (BGA/CSP) на операциях входного и функционального контроля. Результаты работы математической модели описаны и представлены в работах [13, 15].

Так же математическая модель может быть применима к различным известным на сегодняшний день методам проведения соединений, с различными типами стратегий разводки, таких как разводка на косточках, разводка с различными типами переходных отверстий и т.д.

## СПИСОК ЛИТЕРАТУРЫ

1. Стешенко В. Б. ACCEL EDA - PCAD2001: Проектирование печатных плат / В. Б. Стешенко. – М. : «Нолидж», 2005. – 512 с.
2. Курапов С. В. Два подхода к проведению соединений в плоских конструктивах / С. В. Курапов, М. В. Давидовский // Компоненты и технологии. – 2015. – № 7. – С. 142–147.
3. Курапов С. В. Методы построения топологического рисунка графа / С. В. Курапов, А. В. Толок // Автоматика и телемеханика. – 2013. – № 9. – С. 78–97.
4. Барановский И. Современный дизайн и технологии печатных плат: вопрос-ответ Особенности разработки печатных плат с применением микросхем в корпусах BGA [Электрон. ресурс] / И. Барановский. – режим доступа: [http://ictech.com.ua/files/publications/tech\\_articles/ikt\\_05-09.pdf](http://ictech.com.ua/files/publications/tech_articles/ikt_05-09.pdf)
5. Charles Pfeil BGA Breakouts and Routing / C. Pfeil, 2010. – 170 p.
6. Лузин С. САПР TopoR: трассировка печатных плат с BGA-компонентами / С. Лузин, О. Полубасов // Современная электроника. – 2008. – № 7. – С. 44–48.
7. Бухтеев А. Неизвестный САПР страны восходящего солнца – продукты компании Zuken / А. Бухтеев // Электроника : наука, технология, бизнес. – 2004. – № 2. – С. 34–35.
8. Кофман А. Введение в прикладную комбинаторику / А. Кофман. – М. : Наука, ГРФМЛ, 1975. – 480 с.
9. Свами М. Графы, сети и алгоритмы / М. Свами, К. Тхуласираман. – М. : Мир, 1984. – 455 с.
10. Рейнгольд Э. Комбинаторные алгоритмы, теория и практика / [Э. Рейнгольд, Ю. Нивергельт, Н. Дер]. – М. : Мир, 1980. – 480 с.
11. Раппопорт Л. И. Векторная алгебра пересечений / [Л. И. Раппопорт, Б. Н. Мороговский, С. А. Поливцев] // В кн. : Многопроцессорные вычислительные структуры. – Таганрог. – 1982. – Вып. 2 (11). – С. 53–56.
12. Пат. 95190 України: МПК H05K 3/40 Мікроелектромеханічний багатозондовий підмикальний пристрій / [Невлюдов І. Ш., Палагін В. А., Разумов-Фризюк Є. А., Жарікова І. В. та ін.] опубл. 11.07.2011. – Бюл. № 13.
13. Трассировка подключающей пластины многозондового устройства контроля bga-компонентов / [И. В. Жарикова, С. В. Курапов, И. Ш. Невлюдов и др.] // Вісник Запорізького національного університету. Фізико-математичні науки. – 2013. – № 2. – С. 28–36.
14. Вейн Паллием Проектируем платы с BGA / Вейн Паллием, перевод Ю. Потапова. – К. : №5 2002 г.
15. Трассировка подключающей пластины многозондового устройства контроля bga-компонентов / [И. В. Жарикова, С. В. Курапов, И. Ш. Невлюдов, и др.] // Функциональная база нанoeлектроники : VI Международная научная конференция, Харьков – Крым, 30 сентября – 4 октября 2013 г.: тезисы доклада : Харьков. – Крым : ХНУРЭ, 2013. – С. 129–132.

Статья поступила в редакцию 23.02.2016.  
После доработки 28.09.2016.

Курапов С. В.<sup>1</sup>, Чеченя В. С.<sup>2</sup>

<sup>1</sup>Канд. физ.-мат. наук, доцент Запорізького національного університету, Запоріжжя, Україна

<sup>2</sup>Аспірант Запорізького національного університету, Запоріжжя, Україна

## МАТЕМАТИЧНА МОДЕЛЬ ПРОВЕДЕННЯ З'ЄДНАНЬ В ОБЛАСТІ BGA КОМПОНЕНТ

У статті розглянута проблема проектування радіоелектронної апаратури плоских конструктивів в області BGA. Показано, що трасування плоских конструктивів в області BGA не дає бажаних результатів через відсутність універсальної математичної моделі і часто здійснюється вручну. Тому в даній роботі представлена універсальна математична модель, заснована на теоретико-множинному описі розташування з'єднань між контактами BGA компонент для виведення їх на периферію, що дуже важливо при проектуванні плоских конструктивів. Також в роботі наведено детальний опис загального рисунка схеми для плоских конструктивів з матричним розташуванням контактів, таких як BGA, як для з'єднань, які не перетинаються, так і опис розташування з'єднань, які перетинаються. Запропоновано метод визначення перетину провідників для розташування з'єднань, які перетинаються. Показано, що кортеж елементів схеми може бути використаний для опису проведення з'єднань, перевірки завантаження макродискретів і визначення перетину провідників. Запропонована універсальна математична модель може знизити трудомісткість і час проектування топології плоских конструктивів, а також може бути використана для розробки топології мікроелектромеханічних структур різного призначення.

**Ключові слова:** BGA компонент, схема, рисунок, макродискрет, кортеж, множина, канал.



Kurapov S. V.<sup>1</sup>, Chechenja V. S.<sup>2</sup>

<sup>1</sup>Candidate of physical and mathematical sciences, Associate Professor of Zaporizhzhya National University, Ukraine

<sup>2</sup>Postgraduate student of Zaporizhzhya National University, Zaporizhzhya, Ukraine

#### MATHEMATICAL MODEL OF CONNECTION TRACING IN THE AREA OF BGA COMPONENTS

The problem of design of the radio-electronic equipment of printed circuit boards in the field of a BGA component is considered in the paper. This problem is connected with the fact that the trace of plane constructs in the area of BGA component doesn't yield the required results because of the lack of universal mathematical model and usually is routed manually.

This paper presents the universal mathematical model based on multiple description of the location of connection between contacts of BGA components to output them to the outside, which is very important for designing planar constructs. Also, there is a detailed description of the circuit pattern for circuits with matrix arrangement of contacts such as BGA, both location description of crossing and uncrossing compounds. The article proposes the method for determining the location of the intersection of the conductor for intersecting connections. It shows that the set of circuit elements can be used for the description of compounds, fragments and check load conductors intersection determination. The proposed universal model can reduce the complexity and time of topology design of the plane constructs, and can be used to develop topologies of microelectromechanical structures for various purposes.

**Keywords:** BGA component, layout, drawing, discrete, sequence, channel.

#### REFERENCES

1. Steshenko V.B. ACCEL EDA – PCAD2001: Proektirovanie pechatnyh plat. Moscow, Nolidzh, 2005, 512 p.
2. Kurapov S. V., Davidovskij M. V. Dva podhoda k provedeniju soedinenij v ploskih konstruktivah, *Komponenty i tehnologii*, 2015, No. 7, pp. 142–147.
3. Kurapov S. V., Tolok A. V. Metody postroenija topologicheskogo risunka grafa, *Avtomatika i telemekhanika*, 2013, No. 9, pp. 78–97.
4. Baranovskij I. Sovremennij dizajn i tehnologii pechatnyh plat: vopros-otvet Osobennosti razrabotki pechatnyh plat s primeneniem mikroshem v korpusah BGA [Elektron. resurs]. Rezhim dostupa: [http://ictech.com.ua/files/publications/tech\\_articles/ikt\\_05-09.pdf](http://ictech.com.ua/files/publications/tech_articles/ikt_05-09.pdf)
5. Charles Pfeil BGA Breakouts and Routing, 2010, 170 p.
6. Luzin C., Polubasov O. SAPR TopoR: trassirovka pechatnyh plat s BGA-komponentami. Moscow, STA-PRESS, Sovremennaja jelektronika, 2008, No.7, pp. 44–48.
7. Buxteev A. Neizvestnyj SAPR strany vosxodyashhego solnca – produkty kompanii Zuken, *E'lektronika : nauka, texnologiya, biznes*, 2004, No. 2, pp. 34–35.
8. Kofman A. Vvedenie v prikladnuju kombinatoriku. Moscow, Nauka, GRFML, 1975, 480 p.
9. Svami M. Thulasiraman K. Grafy, seti i algoritmy. Moscow, Mir, 1984, 455 p.
10. Rejngol'd Je., Nivergel't Ju., Der N. Kombinatornye algoritmy, teorija i praktika. Moscow, Mir, 1980, 480 p.
11. Rappoport L. I., Morogovskij B. N., Polivcev S. A. Vektornaja algebra persechenij, *V kn.: Mnogoprocessornye vychislitel'nye struktury*, Taganrog, 1982, Vyp. 2(11), pp. 53–56.
12. Nevljudov I. Sh., Palagin V. A., Razumov-Frizjuk Je. A., Zharikova I. V. ta in., Pat. 95190 Ukraïni: MPK N05K 3/40 Mikroelektromehanichnij bagatozondovij pidmikal'nij pristrïj, opubl. 11.07.2011. – Bjul. № 13.
13. Zharikova I. V., Kurapov S. V., Nevljudov I. Sh., Palagin V. A., Razumov-Frizjuk E. A., Chechenja V. S. Trassirovka podkljuchajushhej plastiny mnogozondovogo ustrojstva kontrolja bga-komponentov, *Visnik Zaporiz'kogo nacional'nogo universitetu. Fiziko-matematichni nauki*, 2013, No. 2, pp. 28–36.
14. Vejn Palliem Proektiruem platy s BGA / Vejn Palliem, perevod Ju. Potapova. Kiev, № 5 2002g.
15. Zharikova I. V., Kurapov S. V., Nevljudov I. Sh., Palagin V. A., Razumov-Frizjuk E. A., Chechenja V. S. Trassirovka podkljuchajushhej plastiny mnogozondovogo ustrojstva kontrolja bga-komponentov, *Funkcional'naja baza nanojelektroniki: VI Mezhdunarodnaja nauchnaja konferencija, Har'kov*. Krym, 30 sentjabrja – 4 oktjabrja 2013 g.: tezisy doklada. Har'kov – Krym: HNURJe, 2013, pp. 129–132.

<sup>1</sup>Д-р техн. наук, профессор, директор института информатики и радиоэлектроники Запорожского национального технического университета, Запорожье, Украина

<sup>2</sup>Канд. техн. наук, начальник отделения казенного предприятия «НПК «Искра», Запорожье, Украина

<sup>3</sup>Начальник отдела казенного предприятия «НПК «Искра», Запорожье, Украина

## МЕТОД ФОРМИРОВАНИЯ КЛАССИФИЦИРОВАННОЙ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ АВТОКОМПЕНСАТОРА ПОМЕХ ПРИ ВРЕМЯ-ПРОСТРАНСТВЕННОЙ ФИЛЬТРАЦИИ СИГНАЛОВ

В условиях воздействия комбинированных помех эффективность работы радиолокационных средств существенно ухудшается. Это обусловлено декорреляцией точечного источника активной помехи пространственно-распределенным характером пассивной помехи. Рассмотрены ограничения, возникающие при формировании классифицированной обучающей выборки для адаптации весовых коэффициентов автокомпенсатора помех при время-пространственной обработке сигналов. Разработан новый метод формирования классифицированной обучающей выборки, использующий как спектральные, так и корреляционные отличия в структуре комбинированных помех. Предложенный метод позволяет уменьшить влияние пассивной составляющей комбинированной помехи на процесс компенсации активной составляющей.

**Ключевые слова:** обработка радиолокационных сигналов, адаптивная пространственная фильтрация, комбинированная помеха, классифицированная обучающая выборка, нормированный коэффициент межканальной корреляции.

### ВВЕДЕНИЕ

Наиболее сложным и наиболее вероятным режимом работы в современных условиях является функционирование радиолокационных средств при одновременном воздействии активных маскирующих и пассивных (комбинированных) помех [1]. Возможным методом повышения их помехозащищенности является использование известных последовательных двухэтапных процедур время-пространственной или время-поляризационной фильтрации сигналов [2]. Временная (межпериодная) фильтрация сигналов на фоне пассивных помех в современных радиолокационных станциях (РЛС) выполняется путем использования дискретного преобразования Фурье [3, 4]. Пространственную фильтрацию сигналов преимущественно используют при воздействии активных маскирующих (АМП) помех по боковым лепесткам диаграммы направленности антенны (ДНА) [5]. Поляризационную фильтрацию используют при защите радиолокационных средств от помех, действующих в направлении главного луча ДНА [6].

Пространственную или поляризационную фильтрацию сигналов на фоне АМП реализуют путем использования дополнительных компенсационных каналов приема и различных видов автокомпенсаторов помех или адаптивных антенных решеток. В условиях одновременного воздействия пассивной составляющей комбинированной помехи АМП, генерируемая точечным источником, декоррелируется [7], что приводит к существенному ухудшению ее компенсации. Поэтому проблема формирования классифицированной обучающей выборки для адаптации весовых коэффициентов автокомпенсатора, порожденной только АМП, в современных условиях достаточно актуальна.

### 1 ПОСТАНОВКА ЗАДАЧИ

При время-пространственной фильтрации пространственной обработке предшествует временная межпериодная пачечная обработка принимаемых радиолокационных сигналов. В этом случае пространственная обработка сигналов реализуется в каждом из каналов многоканального доплеровского фильтра. При этом формирование весовых коэффициентов адаптивного пространственного фильтра осуществляется в границах текущей частотной пачки по информации фазовых фильтров основного и компенсационного каналов с номерами  $N/2$ , где  $N$  – общее количество фазовых фильтров [2]. Последнее обусловлено относительно малой вероятностью нахождения пассивной помехи в фильтрах с номером  $N/2$ , где накапливаются сигналы с межпериодным фазовым сдвигом, равным  $180^\circ$ . Однако в реальных условиях работы РЛС при время-пространственной фильтрации фазовые сдвиги пассивной помехи могут достигать и даже превышать значения, равные  $180^\circ$ . Еще одним ограничивающим фактором при формировании классифицированной обучающей выборки в этом случае является межфильтровое «просачивание» пассивной помехи через боковые лепестки смежных фазовых фильтров. Поэтому целью данной работы является разработка метода формирования классифицированной обучающей выборки путем совместного использования спектральных и корреляционных отличий в структуре комбинированных помех.

### 2 АНАЛИЗ ИЗВЕСТНОГО МЕТОДА КОМПЕНСАЦИИ АКТИВНОЙ СОСТАВЛЯЮЩЕЙ КОМБИНИРОВАННОЙ ПОМЕХИ

Временная межпериодная фильтрация в известном методе компенсации активной составляющей комбини-

рованной помехи [2], выполняемая на первом этапе время-пространственной обработки, является пачечной и реализуется использованием дискретного преобразования Фурье, которое выполняется в каждом дискрете дальности частотной пачки:

$$\dot{X}(k) = \sum_{n=0}^{N-1} a_n \dot{X}_i(n) \exp\{j \frac{2n\pi}{N} k\}, \quad (1)$$

где  $\dot{X}(k)$  – комплексное значение сигналов на выходе  $k$ -го фазового фильтра,  $N$  – количество точек преобразования Фурье;  $\dot{X}_i(n)$  – комплексное значение амплитуды сигнала в  $i$ -тый момент времени в  $n$ -ном периоде повторения;  $a_n$  – коэффициенты весового окна;  $k \in [0, N-1]$ .

Комплексное значение сигнала  $\dot{U}_\Sigma$  на выходе пространственного фильтра можно записать в следующем виде:

$$\dot{U}_\Sigma = \dot{U}_0 - \dot{W} \dot{U}_k \quad (2)$$

при этом текущее комплексное значение весового коэффициента  $\dot{W}_{i+1}$  в схеме с использованием классического алгоритма Уидроу [8] определяется как

$$\dot{W}_{i+1} = \dot{W}_i - 2\mu \dot{U}_k^* \dot{U}_\Sigma. \quad (3)$$

В выражениях (2), (3)  $\dot{U}_0$  и  $\dot{U}_k$  – комплексные значения сигналов на основном и на компенсационном входе автокомпенсатора, соответственно,  $\dot{W}_i$  – комплексное значение весового коэффициента на предыдущей итерации;  $\mu$  – скалярная величина, определяющая глубину обратной связи; \* – знак комплексного сопряжения.

Для пояснения сущности анализируемого метода на рис. 1 приведена структурная схема время-пространственной обработки с использованием спектральных отличий пассивной составляющей комбинированной помехи [2]. Схема работает следующим образом. С приемников основного и компенсационного каналов РЛС

на входы устройств временной фильтрации основного 1 и компенсационного 2 каналов поступают сигналы, отраженные от лоцируемых целей, мешающих объектов (пассивные помехи) и шумовые помехи, которые могут излучаться специальными устройствами. С помощью устройств временной фильтрации 1 и 2 происходит когерентное накопление полезных сигналов и распределение по фазовым фильтрам смеси принимаемых сигналов и помех.

Распределенные по фазовым фильтрам сигналы основного и компенсационного каналов, поступают к устройствам памяти основного 3 и компенсационного 4 каналов, где задерживаются на время расчета весового коэффициента в формирователе 6, чтобы рассчитанный весовой коэффициент был использован для компенсации помехи в той частотной пачке, на основании которой производился его расчет.

В качестве обучающей классифицированной выборки в формирователе весовых коэффициентов 6 автокомпенсатора 5 используются выходные сигналы фазовых каналов с номером  $N/2$  компенсационного канала приема и выходного сигнала сумматора 9. Использование фильтровых каналов с номерами  $N/2$  в качестве обучающей классифицированной выборки основано на предположении, что вероятность нахождения пассивной помехи в фазовом канале с номером  $N/2$  с соответствующими доплеровскими сдвигами частоты наименьшая.

На время расчета весового коэффициента в формирователе 6, устройство синхронизации 11 переводит запоминающие устройства 3, 4 и 7 в режим линейной передачи информации. При этом сигналы с фазовых фильтров с номерами  $N/2$  поступают на соответствующие входы автокомпенсатора 5. В формирователе весового коэффициента 6 использован алгоритм вычисления весовых коэффициентов с корреляционной обратной связью (3). После вычисления весового коэффициента устройство синхронизации 11 переводит запоминающее устройство 7 в режим запоминания весового коэффициента




Рисунок 1 – Структурная схема время-пространственной обработки с использованием спектральных отличий

до последующей процедуры адаптации, а запоминающие устройства 3 и 4 – в режим передачи по всем  $N$  каналам. При этом сигналы с выходов запоминающего устройства 4 компенсационного канала в  $N$  умножителях 8 перемножаются на сохраненное в запоминающем устройстве 7 значение весового коэффициента. Результат умножения по каждому из фазовых фильтров поступает ко вторым входам соответствующего сумматора 9, где складывается с информацией с выходов соответствующих фильтров основного канала. Такие вычисления проводят для каждого дискрета дальности текущей частотной пачки. Таким образом проводится процедура пространственной фильтрации и получают распределенные по фазовым фильтрам сигналы, в которых скомпенсирована активная составляющая комбинированной помехи.

Информация с выходов сумматора 9 поступает на устройство некогерентной обработки 10, в котором происходит подавление пассивных помех и обнаружение сигналов, отраженных от целей.

Существенным недостатком используемого в [2] метода формирования классифицированной выборки является низкая эффективность подавления АМП вследствие ее межканальной декорреляции пассивной помехой [7]. Это обусловлено относительно высокой вероятностью наличия пассивной помехи в фильтрах основного и компенсационного канала с номерами  $N/2$ . Действительно, учитывая функциональную связь между частотой Доплера  $F_D$  и радиальной составляющей скорости пассивной помехи  $V_r$

$$F_D = \frac{2V_r}{\lambda}, \quad (4)$$

где  $\lambda$  – длина волны, и, например, при  $\lambda=0,1$  м и  $V_r=20$  м/с, частота Доплера равняется 400 Гц, что может равняться или даже превышать половину частоты повторения импульсов РЛС. При этом пассивная помеха может концентрироваться в фазовом фильтре с номером  $N/2$ . Это подтверждается также результатами регистрации пассивных помех в полигонных условиях.

Кроме того, ограничивающим фактором подавления АМП есть межфильтровое «просачивание» пассивной помехи через боковые лепестки смежных фазовых фильтров. Так, например, при согласованной фильтрации уровень первого бокового лепестка фильтра составляет минус 13 дБ.

### 3 МЕТОД ФОРМИРОВАНИЯ КЛАССИФИЦИРОВАННОЙ ОБУЧАЮЩЕЙ ВЫБОРКИ С ИСПОЛЬЗОВАНИЕМ СПЕКТРАЛЬНЫХ И ВРЕМЕННЫХ ОТЛИЧИЙ В СТРУКТУРЕ ПОМЕХ

Известно, что отражения от преднамеренных пассивных помех имеют локальный характер [9]. Например, размеры облака из одной пачки дипольных отражателей могут составлять 0,5...1 км через 5 минут после сброса и 1,6...2 км через 10 минут после сброса. Наиболее мощные облачные системы с большой удельной площадью рассеяния в разрешаемом объеме (облака вертикального развития типа Cumulus) также имеют локальный характер [10]. Анализ структуры других облачных систем, которые могут находиться на разных ярусах и имеют различную толщину, дает основание считать, что распределение облачных систем по дальности относительно РЛС имеет вероятностный характер.

Таким образом, можно считать, что отраженные от гидрометеоров сигналы (пассивные помехи) имеют нестационарный по дальности (времени) характер. Это может быть использовано для повышения качества формирования классифицированной обучающей выборки для адаптации весовых коэффициентов автокомпенсатора.

Учитывая упомянутое ранее явление декорреляции АМП пассивной помехой, предложен новый метод формирования классифицированной обучающей выборки, в котором для повышения ее качества используются не только спектральные отличия в структуре составляющих комбинированной помехи, но и межканальные корреляционные отличия.

Для пояснения сущности метода формирования классифицированной обучающей выборки на рис. 2 приведена структурная схема время-пространственной обработки с использованием спектральных и корреляционных отличий в структуре комбинированной помехи.

Повышение качества формирования классифицированной обучающей выборки в структурной схеме время-пространственной обработки достигается текущим анализом распределения уровня пассивной составляющей комбинированной помехи, которая является нестационарным по дальности процессом. Такой анализ реализуется путем текущего оценивания модуля межканального нормированного коэффициента корреляции  $|\rho|$  комбинированной помехи на выходах фильтров с номером  $N/2$  основного и компенсационного каналов приема:

$$|\rho| = \frac{|\dot{U}_0 \dot{U}_k^*|}{\sqrt{|\dot{U}_0|^2 |\dot{U}_k|^2}}. \quad (5)$$

В приведенной на рис. 2 структурной схеме устройства с номерами от 1 по 11 аналогичны устройствам рис. 1 с теми же номерами. Анализ распределения пассивной помехи по дальности и выбор интервала, на котором пассивная помеха отсутствует или имеет наименьший уровень осуществляется вычислителем модуля коэффициента межканальной корреляции 12, линией задержки 13 и устройством выбора максимума 14. Вычисление модуля коэффициента межканальной корреляции  $|\rho|$  реализуется методом «скользящего окна» на интервалах, равных  $m$  дискретам дальности. При этом величина  $m$  определяется необходимой длительностью классифицированной обучающей выборки для адаптации весовых коэффициентов автокомпенсатора, а количество интервалов оценивания распределения уровня пассивной помехи по дальности  $p$  равняется количеству отводов линий задержки 13 и зависит от количества дискретов разрешения по дальности РЛС.

Синхронно с вычислением модуля межканального коэффициента корреляции на тех же интервалах выполняется прямое вычисление весовых коэффициентов в формирователе 6 по формуле:

$$\dot{W}_i = \frac{\dot{U}_0 \dot{U}_k^*}{|\dot{U}_k|^2}. \quad (6)$$




Рисунок 2 – Структурная схема время-пространственной обработки с использованием спектральных и корреляционных отличий

После соответствующих вычислений по формулам (5) и (6) и выбора интервала, на котором пассивная помеха отсутствует, что определяется устройством выбора максимума 14, коммутатор 15 подключает соответствующий отвод линии задержки весовых коэффициентов 7 ко вторым входам умножителей 8. Дальнейшая обработка сигналов в устройствах 9 и 10 схемы, представленной на рис. 2, аналогична схеме рис. 1.

#### 4 РЕЗУЛЬТАТЫ

1. Предложен новый метод формирования классифицированной обучающей выборки для адаптации весовых коэффициентов пространственного фильтра при время-пространственной обработке сигналов в когерентно-импульсных РЛС.

2. Впервые при время-пространственной обработке сигналов предложено формировать классифицированную обучающую выборку с учетом не только спектральных отличий между составляющими комбинированной помехи, но и межканальных корреляционных отличий.

3. Повышение качества классифицированной обучающей выборки позволяет уменьшить влияние пассивной помехи на процесс компенсации АМП, что обеспечивает повышение помехозащищенности когерентно-импульсных РЛС в условиях воздействия комбинированных помех.

#### 5 ОБСУЖДЕНИЕ

В результате проведенных исследований установлено, что выбор интервала дальности с наименьшим уровнем пассивной составляющей комбинированной помехи в фазовых каналах с номером  $N/2$  обеспечивает использование как спектральных, так и корреляционных отличий при формировании классифицированной обучающей выборки. Даже если пассивная помеха концентрируется в фазовых каналах с номером  $N/2$ , то с учетом ее нестационарности по дальности оказывается возмож-

ным сформировать классифицированную выборку, порожденную только АМП. Это позволяет при время-пространственной обработке сигналов существенно уменьшить декоррелирующее влияние пассивной помехи на процесс компенсации АМП.

#### ВЫВОДЫ

В статье предложен новый метод формирования классифицированной обучающей выборки, в котором за счет использования межканального корреляционного анализа составляющих комбинированной помехи повышается качество их классификации, что позволяет уменьшить влияние пассивной помехи на процесс адаптации пространственных фильтров при время-пространственной обработке сигналов.

#### БЛАГОДАРНОСТИ

Работа выполнена по научно-исследовательской теме Запорожского национального технического университета «Разработка и усовершенствование алгоритмов комбинированной обработки сигналов в радиотехнических и телекоммуникационных системах» (№ гос. регистрации – 0115U002241). Авторы выражают благодарность МОН Украины и казенному предприятию «Научно-производственный комплекс «Искра» за финансовую поддержку проводимых исследований.

#### СПИСОК ЛИТЕРАТУРЫ

1. Оценка интервала фиксации пространственного весового вектора при последовательной пространственно-временной обработке сигналов на фоне комбинированных помех / [В. П. Рябуха, Д. С. Рачков, А. В. Семеняка, Е. А. Катюшин] // Известия высших учебных заведений. Радиоэлектроника. – 2012. – № 10. – С. 13–25.
2. Пат. 48705 Україна, МПК G01 S 7/36 H04B 15/00. Спосіб компенсації активної складової комбінованої завади / Кононович В. Я., Кукольницький А. П., Залевський О. П., Каспирович О. Г.; Майстер Ю. Л., Денека А. А.; заявник і патентовласник Казенне підприємство «Науково-виробничий комплекс «Іскра». –

- № u200911296; Заявл. 2009.11.06; Опубл. 2010.03.25, Бюл. № 6, 2010 р. – 4 с.
- Тейлор Дж. У. Новая диспетчерская РЛС ASR-9 / Дж. У. Тейлор, Г. Бруникс // ТИИЭР. – 1985. – № 2. – С. 284–289.
  - Радиолокационная станция 36Д6 : учебн. пособие / И. Д. Май [и др.]. – КП «НПК «Искра» – Кн.1, 2006. – 135 с.
  - Теоретические основы радиолокации : учеб. пособие для вузов / Я. Д. Ширман, В. Н. Голиков, И. Н. Бусыгин и др. ; под общ. ред. Я. Д. Ширмана. – М. : Сов. радио, 1970. – 560 с.
  - Пат. 91114 Україна МПК2014 G01S 7/36. Спосіб захисту радіолокаторів від комбінованих завад, діючих на головному променю діаграми спрямованості антени / Піза Д. М. (UA), Сіренко А. С. (UA), Звягинцев Е. А. (UA); заявник і патентовласник: Запорізький національний технічний університет – заявл. 20.12.2013; опубл. 25.06.2014, бюл. № 12, 2014 р.
  - Журавльов А. К. Адаптивные радиотехнические системы с антенными решетками / А. К. Журавльов, В. А. Хлебников и др. – Л. : Изд. Ленинградского университета, 1991. – 544 с.
  - Уидроу Б. Адаптивная обработка сигналов / Б. Уидроу, С. Стирнз; пер. с англ. – М. : Радио и связь, 1989. – 440 с.
  - Радиоэлектронные системы: Основы построения и теория. Справочник. Изд. 2-е, перераб. и доп. / Под ред. Я. Д. Ширмана. – М. : Радиотехника, 2007. – 512 с.
  - Атлас облаков / Федер. служба по гидрометеорологии и мониторингу окружающей среды (Росгидромет), Гл. геофиз. обсерватория им. А. И. Воейкова; [Д. П. Беспалов и др.; ред. Л. К. Сурыгина]. – Санкт-Петербург : Д'АРТ, 2011. – 248 с.

Статья поступила в редакцию 29.06.2016.  
После доработки 21.09.2016.

Піза Д. М.<sup>1</sup>, Лаврент'єв В. М.<sup>2</sup>, Семенов Д. С.<sup>3</sup>

<sup>1</sup>Д-р техн. наук, професор, директор інституту інформатики та радіоелектроніки Запорізького національного технічного університету, Запоріжжя, Україна

<sup>2</sup>Канд. техн. наук, начальник відділення казенного підприємства «НБК «Іскра», Запоріжжя, Україна

<sup>3</sup>Начальник відділу казенного підприємства «НБК «Іскра», Запоріжжя, Україна

#### МЕТОД ФОРМУВАННЯ КЛАСИФІКАЦІЙНОЇ НАВЧАЛЬНОЇ ВИБІРКИ ДЛЯ АВТОКОМПЕНСАТОРА ЗАВАД ПРИ ЧАСОВО-ПРОСТОРОВІЙ ФІЛЬТРАЦІЇ СИГНАЛІВ

В умовах впливу комбінованих завад ефективність роботи радіолокаційних засобів суттєво погіршується. Це обумовлено декорреляцією точкового джерела активної завади просторово-розподіленним характером пасивної завади. Розглянуті обмеження, що виникають при формуванні класифікаційної навчальної вибірки для адаптації вагових коефіцієнтів автокомпенсатора завад при часово-просторовій обробці сигналів. Розроблено новий метод формування класифікаційної навчальної вибірки, що використовує як спектральні, так і кореляційні відмінності в структурі комбінованих завад. Запропонований метод дозволяє зменшити вплив пасивної складової комбінованої завади на процес компенсації активної складової.

**Ключові слова:** обробка радіолокаційних сигналів, адаптивна просторова фільтрація, комбінована завада, класифікована навчальна вибірка, нормований коефіцієнт міжканального кореляції.

Piza D.<sup>1</sup>, Lavrentiev V.<sup>2</sup>, Semenov D.<sup>3</sup>

<sup>1</sup>PhD, professor, Director of the Institute of Informatics and Radioelectronics, Zaporizhzhya National Technical University, Zaporizhzhya, Ukraine

<sup>2</sup>PhD, Department Director, State Enterprise «Scientific and Production complex «Iskra», Zaporizhzhya, Ukraine

<sup>3</sup>Chief of department, State Enterprise «Scientific and Production complex «Iskra», Zaporizhzhya, Ukraine

#### METHOD OF FORMING OF THE CLASSIFIED TRAINING SAMPLE FOR AUTOMATIC CANCELLER OF THE INTERFERENCES WHEN USING TIME-SPACE FILTERING OF SIGNALS

Radar effectiveness is dramatically decreasing in the case of combined interference. This is due to decorrelation of a point source jammer by spatially distributed structure of passive interference. There have been considered limitations arising from the formation of the classified training sample for adaptation of the weighting factors of the automatic jamming canceller in the time-spatial signal processing. A new method has been developed to form the classified training sample, using both the spectral and correlation differences in the structure of combined jamming. The proposed method allows to decrease the effect of the passive component in the combined jamming to the process the active component cancellation.

**Keywords:** Radar signals processing, adaptive space filtering, combined clutter and jamming, ranked training sample, inter-channel correlation coefficient.

#### REFERENCES

- Rjabuha V. P., Rachkov D. S., Semenjaka A. V., Katjushin E. A. Ocenka intervala fiksacii prostranstvennogo vesovogo vektora pri posledovatel'noj prostranstvenno-vremennoj obrabotke signalov na fone kombinirovannyh pomeh, *Izvestija vysshih uchebnyh zavedenij. Radioelektronika*, 2012, No. 10, pp. 13–25.
- Kononovich V. Ja., Kukul'nic'kij A. P., Zalevs'kij O. P., Kaspirovich O. G.; Majster Ju. L., Deneka A. A.; заявник і патентовласник Казенне підприємство «Науково-виробничий комплекс «Іскра» Пат. 48705 Україна, МПК G01 S 7/36 H04B 15/00. Спосіб компенсації активної складової комбінованої завади. № u200911296; Заявл. 2009.11.06; Опубл. 2010.03.25, Бюл. №6, 2010, 4 р.
- Tejlor Dzh. U., Bruniks G. Novaja dispetcherskaja RLS ASR-9, 1985, ТИИЭР, No. 2, pp. 284–289.
- Maj I. D. [i dr.] Radiolokacionnaja stancija 36D6, uchebn. Posobie. KP «NPK «Iskra», 2006, Kn. 1, 135 p.
- Shirman Ja. D., Golikov V. N., Busygin I. N. i dr. ; pod obshh. red. Ja. D. Shirmana Teoreticheskie osnovy radiolokacii, ucheb. posobie dlja vuzov. Moscow, Sov. Radio, 1970, 560 p.
- Piza D. M. (UA), Sirenko A. S. (UA), Zvjahintsev E. A. (UA); заявник і патентовласник. Пат. 91114 Україна МПК2014 G01S 7/36. Спосіб захисту радіолокаторів від комбінованих завад, діючих на головному променю діаграми спрямованості антени. [Текст]. Запорізький національний технічний університет, заявл. 20.12.2013; опубл. 25.06.2014, бюл. № 12, 2014.
- Zhuravl'ov A. K., Hlebnikov V. A. i dr. Adaptivnyje radiotekhnicheskie sistemy s antennymi reshetkami. Leningrad, Izd. Leningradskogo universiteta, 1991, 544 p.
- Uidrou B., Stirnz S. per. s angl. Adaptivnaja obrabotka signalov. Moscow, Radio i svjaz', 1989, 440 p.
- Radioelektronnyje sistemy: Osnovy postroenija i teorija. Spravochnik. Izd. 2-e, pererab. i dop. [Tekst], Pod red. Ja. D. Shirmana. Moscow, Radiotekhnika, 2007, 512 p.
- Bespalov D. P. i dr.; red. Surygina L. K. Atlas oblakov. Feder. sluzhba po gidrometeorologii i monitoringu okružhajushhej sredy (Rosgidromet), Gl. geofiz. observatorija im. A. I. Vojkova. Sankt-Peterburg, D'ART, 2011, 248 p.

# МАТЕМАТИЧНЕ ТА КОМП'ЮТЕРНЕ МОДЕЛЮВАННЯ

## МАТЕМАТИЧЕСКОЕ И КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

### MATHEMATICAL AND COMPUTER MODELLING

УДК 519.213.7, 519.237.7

Шергин В. Л.

Канд. техн. наук, доцент, доцент кафедры искусственного интеллекта, Харьковский национальный университет радиозлектроники, Харьков, Украина

## СВЯЗЬ МЕЖДУ ПАРАМЕТРАМИ САМОПОДОБИЯ, УСТОЙЧИВОСТИ И ДОЛГОСРОЧНОЙ ЗАВИСИМОСТИ ПРИРАЩЕНИЙ ФРАКТАЛЬНОГО ДВИЖЕНИЯ ЛЕВИ

Рассмотрена задача поиска соотношений между параметрами самоподобия, устойчивости и долгосрочной зависимости приращений фрактального движения Леви. В качестве меры взаимосвязи приращений предложено использовать показатели, построенные с помощью модели симметричного перемешивания скрытых факторов, что позволило решить проблему неприменимости корреляционного метода оценки таких приращений, вызванную отсутствием моментов распределения. Получена зависимость показателя взаимосвязи соседних приращений от индексов устойчивости и самоподобия. Эта зависимость имеет вид алгебраического уравнения, которое хоть в общем случае и не имеет явного решения, но легко решается численно. Предложена математическая модель, позволяющая построить аналог дискретной автокорреляционной функции для фрактального движения Леви. Эта модель имеет вид системы алгебраических уравнений. В работе показано, что все аналогичные зависимости, известные для частных случаев процесса фрактального движения Леви, являются соответствующими частными случаями моделей, полученных в работе. Наличие предложенных моделей позволяет определить любой из трех показателей (самоподобия, устойчивости и долгосрочной зависимости приращений) по двум известным, что существенно упростит моделирование и исследование случайных процессов, имеющих вид фрактального движения Леви.

**Ключевые слова:** фрактальное движение Леви, самоподобие, долгосрочная зависимость, устойчивые распределения, показатели взаимосвязи.

### НОМЕНКЛАТУРА

BM – броуновское движение (Brownian motion);  
FBM – фрактальное броуновское движение (fractal Brownian motion);  
FLM – фрактальное движение Леви (fractal Levý motion);  
LP – процесс Леви (Levý process);  
LRD – долгосрочная зависимость приращений (long-range dependency);  
SaS – симметричное альфа-устойчивое (symmetric alpha-stable) распределение;  
SLP – устойчивый процесс Леви (stable Levý process);  
АКФП – автокорреляционная функция приращений;  
НОР – независимые одинаково распределенные;  
СПСФ – симметричное перемешивание скрытых факторов;  
 $Corr\{x, y\}$  – коэффициент корреляции случайных величин  $x, y$ ;  
 $g(x; \alpha, \gamma)$  – плотность распределения случайной величины, следующей  $S\alpha S$ -закону;

$H$  – показатель Херста;  
 $L_\alpha$  – метрика пространства (по Минковскому);  
 $\mathbf{G}$  – диагональная матрица, задающая масштаб наблюдаемых случайных величин;  
 $\mathbf{P}$  – положительно определенная бисимметричная матрица параметров модели характеристической функции;  
 $r_1$  – коэффициент взаимосвязи двух соседних приращений  $r_1(\alpha, H)$ ;  
 $r_n$  – коэффициент взаимосвязи приращений, отстоящих на  $n$  шагов  $r_n(\alpha, H)$ ;  
 $r_{jk}$  – показатель взаимосвязи  $j$ -й и  $k$ -й случайных величин;  
 $\mathbf{u} \in R^n$  – скрытые факторы модели СПСФ (в двумерном случае  $\mathbf{u} = (u, v)^T$ );  
 $\mathbf{x} \in R^n$  – наблюдаемые случайные величины;  
 $X_{k\tau}$  – наблюдаемые значения (одномерного) случайного процесса;  
 $\alpha$  – показатель (индекс) устойчивости ( $0 < \alpha \leq 2$ );

© Шергин В. Л., 2016

DOI 10.15588/1607-3274-2016-3-3

$\gamma$  – параметр масштаба устойчивого распределения ( $\gamma > 0$ );

$\Delta X_{k\tau}$  – приращения случайного процесса  $X_{k\tau}$  на шаге  $k$ ;

$\theta$  – углы поворота косоугольной системы координат скрытых факторов относительно прямоугольной декартовой системы;

$\varphi(t)$  – характеристическая функция случайной величины, следующей  $S\alpha S$ -закону;

$\varphi(\mathbf{t})$  – характеристическая функция совместного распределения многомерной  $S\alpha S$ -величины;

$\psi(\mathbf{t}_1)$  – характеристическая функция совместного распределения скрытых факторов.

## ВВЕДЕНИЕ

Самоподобие является свойством, присущим широкому кругу процессов и явлений естественнонаучного, техногенного, информационного, экономического характера. Если при этом изучаемые процессы или явления подвержены фактору случайности, то говорят о статистическом самоподобии, то есть об инвариантности статистических характеристик случайных процессов относительно аффинных преобразований шкал измерения. Исследование свойств самоподобных случайных процессов представляет интерес как в теоретическом плане, так и с точки зрения практического применения.

Стохастический процесс  $X_t$ ,  $t \geq 0$  называется самоподобным [1], если для любого вещественного значения  $a > 0$  конечномерные распределения для  $X_{at}$  идентичны конечномерным распределениям величины  $a^H X_t$ :

$$\text{Law}\{X_{at}\} = \text{Law}\{a^H X_t\}. \quad (1)$$

Параметр  $H$ , называемый показателем Херста, представляет собой меру самоподобия стохастического процесса.

Другими важными свойствами, также присущими многим процессам и явлениям, являются «тяжелые хвосты» распределений и долгосрочная зависимость приращений (LRD) исследуемых процессов.

Объектом исследований настоящей работы является случайный процесс, обладающий всеми тремя перечисленными свойствами и носящий название фрактального движения Леви (FLM). Предметом исследования являются количественные соотношения между параметрами самоподобия, устойчивости и долгосрочной зависимости приращений FLM.

Свойства самоподобия, устойчивости и долгосрочной зависимости приращений взаимосвязаны между собой, в то же время вид этой зависимости в общем случае неизвестен. Что и обуславливает актуальность настоящей работы, целью которой как раз и является установление количественных соотношений между параметрами, характеризующими указанные свойства исследуемого процесса.

Для достижения поставленной цели необходимо в первую очередь описать исследуемые свойства количественно, т.е. параметризовать их. После этого следует составить математическую модель, связывающую эти параметры, и, в-третьих, построить и проанализировать

зависимость между исследуемыми параметрами, протекающую из найденной математической модели.

## 1 ПОСТАНОВКА ЗАДАЧИ

Основная сложность в решении поставленной проблемы, на взгляд автора, состоит в том, что свойство долгосрочной зависимости приращений случайных процессов принято описывать с помощью автокорреляционной функции самого случайного процесса, или его приращений. В то же время, альфа-устойчивые случайные величины (при  $\alpha \neq 2$ ) не обладают моментами второго порядка, а значит, такой подход в этом случае неприменим.

Таким образом, первой подзадачей, решаемой в настоящей работе, является выбор показателей, пригодных для описания явления взаимосвязи величин, следующих устойчивому распределению. Такие показатели, очевидно, должны быть инвариантны к наличию или отсутствию моментов распределения и в то же время, для частного (гауссовского) случая  $\alpha = 2$  должны совпадать с соответствующими показателями взаимосвязи гауссовских случайных величин.

Второй подзадачей, решаемой в данной работе, является построение математических моделей, связывающих показатели устойчивости ( $\alpha$ ), самоподобия ( $H$ ) и коэффициенты взаимосвязи двух соседних ( $r_1$ ), или отстоящих на  $n$  шагов ( $r_n$ ) приращений FLM. Очевидно, что зависимости  $r_1(\alpha, H)$ ,  $r_n(\alpha, H)$ , следующие из предлагаемых общих моделей, должны совпадать с аналогичными зависимостями в тех частных случаях FLM, для которых они уже известны.

Получение этих зависимостей, их визуализация и анализ свойств являются третьей подзадачей настоящей работы.

## 2 ОБЗОР ЛИТЕРАТУРЫ

Простейшим самоподобным случайным процессом (1) является броуновское движение (для которого  $H = 1/2$ ), обладающее такими свойствами, как [2] нулевое начало, стационарность приращений, стохастическая непрерывность траекторий, независимость приращений, гауссовость приращений. Первые три из перечисленных свойств являются общими для всех моделей, рассматриваемых в настоящей работе.

Обобщениями броуновского движения служат устойчивый процесс Леви (SLP) и фрактальное броуновское движение (FBM). В первом случае гауссовский закон распределения приращений ( $\alpha = 2$ ) обобщается до альфа-устойчивого ( $0 < \alpha \leq 2$ ). Такое обобщение позволяет дополнить свойство самоподобия другим важным свойством – «тяжелыми хвостами» распределений [3]:

$$\begin{aligned} P\{X > x\} &\sim x^{-\alpha}, & x \rightarrow \infty \\ P\{X < x\} &\sim |x|^{-\alpha}, & x \rightarrow -\infty \end{aligned} \quad \text{при } \alpha \neq 2. \quad (2)$$

Параметр  $\alpha$ ,  $0 < \alpha \leq 2$ , называется индексом устойчивости и определяет «тяжесть хвостов» распределения (2). Плотности распределений симметричных устойчивых ( $S\alpha S$ ) законов  $g(x; \alpha, \gamma)$  параметризуются в частотной области, т.е. с помощью характеристической функции:

$$\varphi(t) = M(e^{itx}) = \int_{-\infty}^{\infty} e^{itx} g(x; \alpha, \gamma) dx = \exp(-|\gamma t|^\alpha). \quad (3)$$



Параметр  $\gamma > 0$  задает масштаб: если случайная величина  $X$  стандартизована, т.е.  $\gamma_x = 1$ , и  $Y = cX$ , то  $\gamma_y = |c|$ .

Важнейшим свойством устойчивых законов является то, что сумма независимых одинаково распределенных (НОР) случайных величин  $X_k$  ( $k = 1, \dots, n$ ), следующих (3), также следует устойчивому закону (3):

$$Y_n = X_1 + X_2 + \dots + X_n \rightarrow g(y; \alpha, n^{1/\alpha} \gamma). \quad (4)$$

Альфа-устойчивые законы (3) являются далеко не единственными, обладающими «тяжелыми хвостами». Например, используются гиперболические законы [2]. Особое место альфа-устойчивых распределений обусловлено тем, что эти и только эти законы могут быть пределом по распределению сумм независимых одинаково распределенных (НОР) случайных величин [4]. Это значит, что даже если  $X_k$  не являются устойчивыми, но при этом являются НОР (и симметричными), то предел по распределению их суммы  $Y_n$  при  $n \rightarrow \infty$  либо не существует, либо имеет вид (4).

Случайный процесс с независимыми альфа-устойчивыми приращениями  $\Delta X_k = X_{k\tau} - X_{(k-1)\tau}$ , следующими  $S\alpha S$ -закону (3) называется устойчивым процессом Леви [3] и, как следует из (1) и (4), является самоподобным с показателем Херста

$$H = 1/\alpha. \quad (5)$$

Случайный процесс  $X(t)$  называется процессом, обладающим свойством LRD, если автокорреляционная функция его приращений (АКФП)  $\Delta X_k = X_{k\tau} - X_{(k-1)\tau}$  асимптотически убывает не быстрее, чем степенная функция с показателем  $-b$ ,  $0 < b < 2$ :

$$r_n = \text{Corr}\{\Delta X_k \Delta X_{k+n}\} \sim n^{-b}, \quad n \rightarrow \infty. \quad (6)$$

Доказано [2, 5, 6], что самоподобный случайный процесс (1) со стационарными приращениями и конечной дисперсией имеет АКФП вида

$$r_n = \frac{1}{2} \left( (n+1)^{2H} + (n-1)^{2H} - 2n^{2H} \right) \underset{n \rightarrow \infty}{=} H(2H-1)n^{2H-2}, \quad (7)$$

$$0 < H < 1.$$

Таким образом, при  $H \neq 1/2$  самоподобный случайный процесс характеризуется наличием долгосрочной зависимости приращений с показателем

$$b = 2 - 2H. \quad (8)$$

Процесс (1) с АКФП (7) называется фрактальным броуновским движением (ФБМ) [1].

Рассмотренные модели ВМ, ФБМ и SLP являются частными случаями процесса FLM, обладающего всеми тремя описанными свойствами: самоподобием (1), «тяжелыми хвостами» (2) и долгосрочной зависимостью (6). Числовыми мерами этих свойств являются соответственно  $H, \alpha, r_n$ . Модели ВМ соответствуют значения  $\alpha = 2, H = 1/2, r_n = 0$ , модели ФБМ –  $\alpha = 2, 0 < H < 1, r_n = H(2H-1)n^{2H-2}$ , модели SLP –  $0 < \alpha \leq 2, H = 1/\alpha, r_n = 0$ . Очевидно, что параметры

$H, \alpha, r_n$  для FLM-процесса взаимосвязаны между собой, в то же время вид этой зависимости неизвестен. Вывод соотношения, связывающего указанные параметры, и является основной целью настоящей работы.

### 3 МАТЕРИАЛЫ И МЕТОДЫ

Как было отмечено в постановке задачи, корреляционная модель взаимосвязи неприменима для величин, следующих устойчивым законам распределения (при  $\alpha \neq 2$ ) в силу отсутствия вторых моментов. Как указывается в [6], для описания явления взаимосвязи величин, следующих распределению (3), необходимы иные показатели, инвариантные к наличию или отсутствию моментов. Естественно потребовать, чтобы при  $\alpha = 2$  (т.е. для гауссовского закона распределения) эти показатели переходили в традиционные коэффициенты корреляции.

В [7] было показано, что взаимосвязь между двумя случайными величинами, можно описать с помощью модели симметричного перемешивания скрытых факторов (СПСФ):

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} a & b \\ b & a \end{pmatrix} \begin{pmatrix} u \\ v \end{pmatrix}, \text{ или } \mathbf{x} = \mathbf{P} \cdot \mathbf{u}. \quad (9)$$

Согласно этой модели взаимосвязь наблюдаемых одинаково распределенных случайных величин  $(x, y)$  обусловлена перемешиванием независимых (и также одинаково между собой распределенных) ненаблюдаемых случайных величин  $(u, v)$ .

Очевидно, что модель (9) инвариантна к виду законов распределения рассматриваемых величин, к наличию или отсутствию моментов.

Известно [4], что линейная комбинация конечного числа независимых случайных величин  $X_k$ , следующих  $S\alpha S$ -распределению (5) с одним и тем же индексом устойчивости ( $\alpha$ ), также следует этому же распределению. А именно, если  $X_k \rightarrow g(x; \alpha; \gamma_k)$  ( $k = 1, \dots, n$ ), то

$$Y_n = \sum_{k=1}^n c_k X_k \rightarrow g(y; \alpha; \gamma_0). \quad (10)$$

При этом параметры масштаба связаны соотношением

$$\gamma_0^\alpha = \sum_{k=1}^n (\gamma_k \cdot |c_k|)^\alpha. \quad (11)$$

Без нарушения общности можно принять масштабы случайных величин, входящих в (9), за единицу. Тогда из (11) следует, что

$$|a|^\alpha + |b|^\alpha = 1. \quad (12)$$

Выражение (12) представляет собой уравнение единичной окружности в метрике  $L_\alpha$ , а параметры  $a$  и  $b$  представляют собой абсциссу и ординату точки этой окружности, соответствующей полярному углу  $\theta$ :

$$a = \frac{\cos \theta}{(|\cos \theta|^\alpha + |\sin \theta|^\alpha)^{1/\alpha}},$$

$$b = \frac{\sin \theta}{\left( |\cos \theta|^\alpha + |\sin \theta|^\alpha \right)^{1/\alpha}}, \quad |\theta| \leq \frac{\pi}{4}. \quad (13)$$

В силу линейности преобразования Фурье характеристическая функция  $\varphi(\mathbf{t})$  ( $\mathbf{t} = (s, t)'$ ) вектора  $\mathbf{x} = \mathbf{P}\mathbf{u}$  (9) связана с характеристической функцией  $\psi(\mathbf{t}_1)$  вектора  $\mathbf{u}$  простым соотношением:

$$\begin{aligned} \log \varphi(\mathbf{t}) &= \log \psi(\mathbf{P}'\mathbf{t}) = \log \psi(sa + tb, sb + ta) = \\ &= -|sa + tb|^\alpha - |sb + ta|^\alpha. \end{aligned} \quad (14)$$

Многомерные  $S\alpha S$ -распределения, в отличие от одномерных (3), в общем случае не могут быть описаны конечным набором параметров. Существует несколько форм параметризации таких законов, рассмотренных в работах [8, 9]. В настоящей работе используется параметризация [8], согласно которой требуемый набор параметров состоит из  $1 \leq m \leq \infty$  положительно полуопределенных симметрических матриц  $\Omega(j)$ :

$$\log \varphi(\mathbf{t}) = -\sum_{j=1}^m (\mathbf{t}'\Omega(j)\mathbf{t})^{\alpha/2}, \quad (15)$$

Для многомерного устойчивого распределения, параметризованного в форме (15), существует показатель взаимосвязи:

$$r_{jk} = \frac{\sum_{l=1}^m \Omega_{jk}(l)}{\sqrt{\sum_{l=1}^m \Omega_{jj}(l) \cdot \sum_{l=1}^m \Omega_{kk}(l)}}, \quad j, k = 1, \dots, n \quad (16)$$

Так как форма (14) является частным случаем (15) (при  $m = 2$ ,  $\Omega(1) = (a, b)' \cdot (a, b)$ ,  $\Omega(2) = (b, a)' \cdot (b, a)$ ), то показатель взаимосвязи (16) величин  $(x, y)$  имеет вид

$$r = \frac{2ab}{a^2 + b^2} = \sin(2\theta). \quad (17)$$

Нетрудно видеть, что в частном случае  $\alpha = 2$ , соответствующем гауссовскому распределению, показатели (16)–(17) совпадают с обычным коэффициентом корреляции.

Модель СПСФ имеет наглядную геометрическую интерпретацию: линейное преобразование (9), описывает переход от «естественной» косоугольной системы координат скрытых факторов к прямоугольной, соответствующей наблюдаемым случайным величинам. Из-за наличия взаи-

мосвязи происходит искажение «эллипсов» рассеивания (т.е. кривых постоянной плотности): они вытягиваются (или сжимаются при  $r < 0$ ) вдоль биссектрисы главного угла (рис. 1). При этом показатели взаимосвязи (17) равны косинусам соответствующих координатных углов системы координат скрытых факторов ( $r = \cos(\eta) = \sin(2\theta)$ ).

Модель СПСФ (9) легко обобщается [7] на случай, когда рассматриваемые зависимые переменные имеют разный масштаб и/или их количество  $n > 2$ . Если обозначить  $\mathbf{x} \in R^n$  – вектор наблюдаемых случайных величин,  $\mathbf{G} = \text{diag}(\gamma_1, \dots, \gamma_n)$  – диагональная матрица, задающая их масштаб,  $\mathbf{u} \in R^n$  – вектор скрытых факторов,  $\mathbf{P}$  – положительно определенная бисимметричная (симметричная относительно обеих диагоналей) матрица факторного преобразования, то преобразование (9) приобретает вид

$$\mathbf{x} = \mathbf{G}\mathbf{P}\mathbf{u}. \quad (18)$$

а характеристическая функция (14) – форму

$$\log \varphi(\mathbf{t}) = -\sum_{j=1}^n \left( \left| \sum_{k=1}^n p_{jk} \gamma_k t_k \right|^\alpha \right). \quad (19)$$

Масштабы скрытых факторов удобно без нарушения общности принять за единицу, тогда коэффициенты матрицы  $\mathbf{P}$  должны удовлетворять помимо условий симметрии  $p_{jk} = p_{kj}$  и антисимметрии  $p_{jk} = p_{n+1-k, n+1-j}$ , условиям нормировки в метрике  $L_\alpha$ , аналогичным (12):

$$\|\mathbf{P}_j\|_\alpha = \sum_{k=1}^n |p_{jk}|^\alpha = 1, \quad \forall j = 1, \dots, n. \quad (20)$$

Коэффициенты взаимосвязи  $r_{jk}$  находятся по формуле (16) при  $m = 1$  и  $\Omega = \mathbf{P}'\mathbf{P}$ , т.е.  $r_{jk} = \Omega_{jk} / \sqrt{\Omega_{jj}\Omega_{kk}}$ . Таким образом, матрица  $\Omega = \mathbf{P}'\mathbf{P}$  играет роль ковариационной.

Для процесса FBM (являющегося частным случаем рассматриваемой модели FLM, соответствующего  $\alpha = 2$ ), вид зависимости коэффициента взаимосвязи двух соседних приращений ( $r_1$ ) от  $\alpha$  и  $H$  известен. Эта зависимость является частным случаем АКФП  $r_n$  (7) (соответствующим  $n = 1$ ) и имеет следующий вид:

$$r_1(\alpha = 2, H) = \text{Corr}\left\{ (X_{k\tau} - X_{(k-1)\tau}) (X_{(k+1)\tau} - X_{k\tau}) \right\} = 2^{2H-1} - 1. \quad (21)$$




Рисунок 1 – Геометрическая интерпретация взаимосвязи (корреляции) двумерного альфа-устойчивого распределения

С помощью модели СПСФ можно найти зависимость  $r_1(\alpha, H)$  для общего случая, соответствующего исследуемому процессу FLM.

Характеристическая функция  $\varphi(\mathbf{t})$  двумерного устойчивого распределения соседних приращений  $\Delta X_{k\tau}$ ,  $\Delta X_{(k+1)\tau}$  имеет вид (14). В силу свойства самоподобия (1) приращение исследуемого случайного процесса за два такта имеет масштаб, равный  $2^H$ . С другой стороны, из (11) и (14) следует, что  $x + y$  имеет масштаб  $\gamma_{x+y}$ , удовлетворяющий равенству  $\gamma_{x+y}^\alpha = 2|a+b|^\alpha$ . Таким образом,

$$2^{1/\alpha} |a+b| = 2^H. \quad (22)$$

Коэффициент взаимосвязи между приращениями вычисляется по формуле (17), для чего необходимо найти параметры  $a, b$  из условия нормировки (12) и соотношения (22). Подставив (13) в (22), и обозначив  $z = \tan(\theta)$ , получим:

$$\frac{(1+z)^\alpha}{1+|z|^\alpha} = 2^{\alpha H-1}, \quad -1 \leq z \leq 1. \quad (23)$$

При этом искомый коэффициент взаимосвязи приобретает вид:

$$r_1 = \sin(2 \cdot \arctan(z)) = \frac{2z}{1+z^2}. \quad (24)$$

Зависимость коэффициента взаимосвязи соседних приращений FLM от индексов устойчивости и самоподобия  $r_1(\alpha, H)$ , в общем случае не выражается через элементарные функции. Для ее построения следует численно решить уравнение (23). Интересно отметить, что при  $H=0$  и  $\alpha \rightarrow 0$  решение (23) стремится к  $z(0,0) = \tau - 1$ , где  $\tau = \frac{\sqrt{5}-1}{2} \approx 0,618\dots$  – золотое сечение!

При этом  $r_1(0,0) = -\frac{2}{3}$ .

Для расчета показателя взаимосвязи  $r_n$  между двумя приращениями процесса FLM, отстоящими на  $n$  тактов, следует применить обобщенную модель СПСФ (18)–(19). Обозначим  $x_1 = \Delta X_{k\tau} = X_{k\tau} - X_{(k-1)\tau}$ ,  $x_2 = X_{(k+n-1)\tau} - X_{k\tau}$ ,  $x_3 = \Delta X_{(k+n)\tau} = X_{(k+n)\tau} - X_{(k+n-1)\tau}$ . Рассматриваемые случайные величины  $x_1, x_2, x_3$  следуют устойчивым распределениям. Величины  $x_1$  и  $x_3$  в силу свойства стационарности приращений имеют одинаковый масштаб, который примем за единицу. Величина  $x_2$  согласно свойствам стационарности и самоподобия имеет масштаб  $\gamma = (n-1)^H$ . Характеристическая функция  $\varphi(\mathbf{t})$  совместного распределения  $x_1, x_2, x_3$  имеет вид (19), при этом  $3 \times 3$  матрица  $\mathbf{P}$  в силу бисимметричности содержит четыре неизвестных коэффициента  $a, b, c, d$ :

$$\mathbf{P} = \begin{pmatrix} a & b & c \\ b & d & b \\ c & b & a \end{pmatrix}, \quad \mathbf{G} = \begin{pmatrix} 1 & & \\ & \gamma & \\ & & 1 \end{pmatrix}. \quad (25)$$

Таким образом,

$$\log \varphi(\mathbf{t}) = -|a t_1 + b \gamma t_2 + c t_3|^\alpha - |b t_1 + d \gamma t_2 + b t_3|^\alpha - |c t_1 + b \gamma t_2 + a t_3|^\alpha. \quad (26)$$

Неизвестные коэффициенты  $(a, b, c, d)$  находятся из следующей системы:

$$\begin{cases} |a|^\alpha + |b|^\alpha + |c|^\alpha = 1 \\ |b|^\alpha + |d|^\alpha + |b|^\alpha = 1 \\ |a+b\gamma|^\alpha + |b+d\gamma|^\alpha + |c+b\gamma|^\alpha = n^{\alpha H} \\ |a+b\gamma+c|^\alpha + |b+d\gamma+b|^\alpha + |c+b\gamma+a|^\alpha = (n+1)^{\alpha H} \end{cases} \quad (27)$$

Первые два уравнения этой системы являются стандартными условиями нормировки (20), третье следует из того, что случайные величины  $x_1 + x_2 = X_{(k+n-1)\tau} - X_{(k-1)\tau}$  и  $x_2 + x_3$  имеют масштаб, равный  $n^H$ , а четвертое отражает равенство  $(n+1)^H$  масштаба величины  $x_1 + x_2 + x_3 = X_{(k+n)\tau} - X_{(k-1)\tau}$ .

Искомый коэффициент взаимосвязи (между  $x_1$  и  $x_3$ ) определяется согласно (16) (как отмечалось выше, при  $m=1$ ,  $\Omega = \mathbf{P} \cdot \mathbf{P}$ ):

$$r_n = \frac{\Omega_{13}}{\sqrt{\Omega_{11} \cdot \Omega_{33}}} = \frac{2ac + b^2}{a^2 + b^2 + c^2}. \quad (28)$$

К сожалению, система (27) имеет явное решение только при  $\alpha=2$  (в этом случае  $r_n$  имеет вид (7)), а также при  $\alpha=1$  ( $\lim_{n \rightarrow \infty} r_n = \frac{1}{4} n^{-2H}$ ). В остальных случаях систему (27) необходимо решать численно, и при этом даже асимптотическое (при  $n \rightarrow \infty$ ) поведение показателей взаимосвязи (28) неизвестно.

#### 4 ЭКСПЕРИМЕНТЫ

Для численного решения уравнения (23) и нахождения зависимости коэффициента взаимосвязи соседних приращений FLM от индексов устойчивости и самоподобия (24) использовался пакет SciLab-5.4.0. Значения  $H$  варьировались от 0 до 1 с шагом 0,05; значения  $\alpha$  – 0,001 и затем от 0,05 до 2 с шагом 0,05. Решение уравнения (23) выполнялось с точностью  $tol = 10^{-6}$ . При решении (23) учитывалось, что функция от вспомогательной переменной  $z$ , стоящая в левой части, является немонотонной и невыпуклой при  $\alpha < 1$ . Поэтому при  $\alpha < 1$  диапазон допустимых значений  $z$  ограничивался значениями  $-1$  и  $0$ , в то время как при  $\alpha \geq 1$  ограничения имели вид  $-1 \leq z \leq 1$ .

#### 5 РЕЗУЛЬТАТЫ

Получена зависимость показателя взаимосвязи соседних приращений исследуемого процесса FLM (фрактального движения Леви)  $r_1(\alpha, H)$  от индексов устойчивости ( $\alpha$ ) и самоподобия ( $H$ ). Она имеет вид алгебраических уравнений (23)–(24). В процессе экспериментальных исследований был получен график указанной зависимости  $r_1(\alpha, H)$ , представленный на рис. 2.




Рисунок 2 – Зависимость коэффициента взаимосвязи двух соседних приращений фрактального процесса Леви от индексов устойчивости и самоподобия

На рисунке для сравнения также показаны зависимости  $r_1(\alpha, H)$ , соответствующие известным частным случаям FLM: процессу SLP (сплошная линия) и процессу FBM (пунктирная линия).

Как видно из графика, экспериментальное исследование полностью подтвердило результаты теоретических исследований, а именно, полученная в работе математическая модель  $r_1(\alpha, H)$  (23)–(24), описывающая взаимосвязь между параметрами процесса FLM, не противоречит аналогичным зависимостям, соответствующим известным частным случаям (SLP, FBM, BM), но при этом обобщает их.

В работе также предложена математическая модель (27)–(28) в форме системы алгебраических уравнений, теоретически позволяющая построить аналог дискретной автокорреляционной функции приращений для FLM, то есть зависимость показателя взаимосвязи элементарных приращений, отстоящих на  $n$  тактов  $r_n(\alpha, H)$  от индексов устойчивости и самоподобия.

## 6 ОБСУЖДЕНИЕ

Свойства самоподобия, устойчивости и долгосрочной зависимости приращений фрактального движения Леви взаимосвязаны между собой, однако количественные соотношения между соответствующими параметрами были известны лишь для некоторых частных случаев (BM, FBM [5], SLP[6]).

Основным, по мнению автора, препятствием на пути построения общей модели была невозможность количественного описания свойства зависимости приращений в рамках традиционного дисперсионно-ковариационного подхода. Для решения этой проблемы было предложено использовать показатели взаимосвязи, построенные с помощью модели СПСФ.

В результате теоретических исследований была получена математическая модель в форме системы алгебраических уравнений, связывающих индексы самоподобия, устойчивости и показатель взаимосвязи соседних приращений. Показано теоретически и подтверждено экспериментально, что для частных случаев фрактального движения Леви (BM, FBM, SLP) решения полученной системы полностью соответствуют известным зависимостям, соответствующим этим частным моделям.

Таким образом, предложенная модель может рассматриваться как обобщение ранее известных [5, 6] на процесс (FLM) более общего вида.

Была также получена еще более общая модель, связывающая индексы самоподобия и устойчивости с показателем взаимосвязи приращений, отстоящих на  $n$  тактов. Для нее также было показано, что она включает в себя все известные модели процессов, являющихся частными случаями FLM [2, 5, 6], и обобщает их.

## ВЫВОДЫ

В работе решена задача поиска соотношений между параметрами, отвечающими за свойства самоподобия, устойчивости и долгосрочной зависимости приращений фрактального движения Леви.

Научная новизна полученных результатов состоит в том, что:

1. Впервые предложено для оценки взаимосвязи приращений фрактального движения Леви использовать показатели, построенные с помощью модели симметричного перемешивания скрытых факторов, что позволило решить проблему неприменимости корреляционного метода их оценки.

2. Впервые получена математическая модель, описывающая зависимость показателя взаимосвязи соседних приращений фрактального движения Леви от индексов устойчивости и самоподобия. Указанная зависимость построена экспериментально в графическом виде.

3. Впервые построена математическая модель, позволяющая построить аналог дискретной автокорреляционной функции для фрактального движения Леви, то есть зависимость показателя взаимосвязи элементарных приращений, отстоящих на  $n$  тактов от индексов устойчивости и самоподобия.

Практическая значимость полученных результатов состоит в том, что наличие предложенных моделей позволяет определить один из трех показателей (самоподобия, устойчивости и долгосрочной зависимости приращений) по двум известным, что существенно упрощает моделирование и исследование случайных процессов, имеющих вид фрактального движения Леви.

Несмотря на возможность построить аналог дискретной автокорреляционной функции для фрактального движения Леви с помощью полученной модели, асимптотический вид (при  $n \rightarrow \infty$ ) этой зависимости остался неизвестным. Очевидно, что ее нахождение и экспериментальное подтверждение является актуальным направлением для дальнейших исследований.

## СПИСОК ЛИТЕРАТУРЫ

1. Mandelbrot B. Fractional Brownian motions, fractional noises and applications / B. Mandelbrot, J.W. van Ness // SIAM Review. – 1968. – Vol. 10 (4) – P. 422–437. DOI:10.1137/1010093.
2. Ширяев А. Н. Основы стохастической финансовой математики. Том 1. Факты. Модели / А. Н. Ширяев. – М. : ФАЗИС, 1998. – 512 с.
3. Мандельброт Б. Фрактальная геометрия природы / Б. Мандельброт. – М. : «Институт компьютерных исследований», 2002. – 656 с.
4. Золотарев В. М. Одномерные устойчивые распределения / В. М. Золотарев. – М. : Наука, 1983. – 304 с.
5. Федер Е. Фракталы / Е.Федер. – М. : Мир, 1991. – 261 с.

6. Samorodnitsky G. Stable Non-Gaussian Random Processes, Chapter 7: «Self-similar processes» / G. Samorodnitsky, M. S. Taqqu. – Chapman & Hall, 1994.
7. Шергін В. Інтерпретація показателя взаємозв'язку багатовимірних устійливих випадкових величин з допомогою факторної моделі / В. Шергін // Восточно-Европейський журнал передових технологій. – 2015. – 5 (4(77)) – С. 44–49. DOI:10.15587/1729-4061.2015.50442
8. Press S. J. Multivariate stable distributions / S. J. Press // Journal of Multivariate Analysis. – 1972. – Vol. 2, Issue 4. – P. 444–462. DOI: 10.1016/0047-259x(72)90038-3
9. Balakrishnan N.: Continuous bivariate distributions [Text] / N. Balakrishnan, C.-D. Lai. – Springer, 2009. – 684 p. DOI: 10.1007/b101765

Статья поступила в редакцию 16.02.2016.  
После доработки 24.02.2016.

Шергін В. Л.

Канд. техн. наук, доцент, доцент кафедри штучного інтелекту, Харківський національний університет радіоелектроніки, Харків, Україна

#### **ЗВ'ЯЗОК МІЖ ПАРАМЕРАМИ САМОПОДІБНОСТІ, СТІЙКОСТІ ТА ДОВГОСТРОКОВОЇ ЗАЛЕЖНОСТІ ПРИРІСТІВ ФРАКТАЛЬНОГО РУХУ ЛЕВІ**

Розглядається задача пошуку співвідношень між параметрами, самоподібності, стійкості та довгострокової залежності приростів фрактального руху Леві. В якості міри взаємозв'язку приростів, запропоновано застосувати показники, побудовані за допомогою моделі симетричного перемішування прихованих факторів, що дало змогу розв'язати проблему непридатності кореляційного методу оцінки таких приростів, пов'язану з відсутністю потрібних моментів розподілу. Отримано залежність показника взаємозв'язку сусідніх приростів від індексів стійкості та самоподібності. Ця залежність має вигляд алгебраїчного рівняння, яке хоч в загальному випадку й не має явного рішення, але легко розв'язується чисельно. Запропоновано математичну модель, яка дозволяє побудувати аналог дискретної автокореляційної функції для фрактального руху Леві. Ця модель має вигляд системи алгебраїчних рівнянь. В роботі показано, що всі аналогічні залежності, які є відомими для окремих випадків процесу фрактального руху Леві, який розглядається, є відповідними окремими випадками моделей, отриманих у роботі. Наявність запропонованих моделей дає змогу визначити будь-який з трьох показників (самоподібності, стійкості та довгострокової залежності приростів) по двом відомим, що суттєво спрощує моделювання та дослідження випадкових процесів, які мають вигляд фрактального руху Леві.

**Ключові слова:** фрактальний рух Леві, самоподібність, довгострокова залежність, стійки розподіли, показники взаємозв'язку.

Shergin V. L.

PhD., Associate Professor, Associate Professor of Artificial intelligence department, Kharkov National University of Radioelectronics, Kharkov, Ukraine

#### **RELATIONSHIP BETWEEN THE PARAMETERS OF SELF-SIMILARITY, STABILITY AND LONG-RANGE DEPENDENCY OF FRACTAL LEVÝ MOTION**

The problem of searching relationships between the parameters of self-similarity, stability and long-range dependency of fractal Levý motion is considered. It was proposed to use indexes, constructed by means of a model of symmetric mixing of latent factors as a measure of the relationship between increments of fractal Levý motion process. This approach makes it possible to solve the problem of inability to use the correlation method for estimating such increments caused by the absence of the required distribution moments. Dependence of the relationship index of neighboring increments on the indices of stability and self-similarity is obtained. This dependence has the form of an algebraic equation which has no an explicit solution generally, but can be easily solved numerically. A mathematical model that allows to construct a discrete analogue of the autocorrelation function for the fractal Levý motion is proposed. This model has the form of the system of algebraic equations. It is shown that all of the similar dependencies known for the particular cases of the fractal Levý motion, are special cases of the models obtained in the work. Proposed models allow us to determine any of the three parameters (self-similarity, stability and long-range dependency) on two other that will essentially simplify the modeling and studying stochastic processes having the form of fractal Levý motion.

**Keywords:** fractal Levý motion, self-similarity, long-range dependency, stable distributions, relationship indexes.

#### **REFERENCES**

1. Mandelbrot B. B., Van Ness J. W. Fractional Brownian Motions, Fractional Noises and Applications, *SIAM Review*, 1968, 10(4), pp. 422–437. DOI: 10.1137/1010093.
2. Shiryaev A. N. Essentials of Stochastic Financial Mathematics. Volume 1. Facts. Models. Moscow, Fakis, 1998, 512 p.
3. Mandelbrot B. B. The Fractal Geometry of Nature, *American Journal of Physics*, 1983, Vol. 51(3), P. 286. DOI: 10.1119/1.13295.
4. Zolotarev V. M. One-dimensional stable distributions. American Mathematical Society, 1986.
5. Feder, J. (1988). Fractals. Springer, 283 p. DOI: 10.1007/978-1-4899-2124-6.
6. Samorodnitsky G., Taqqu M. S. (1994), Stable Non-Gaussian Random Processes, Chapter 7: «Self-similar processes» (Chapman & Hall).
7. Shergin V. Interpretation of the measure of dependence for multivariate stable random variables using factor model, *Eastern-European Journal Of Enterprise Technologies*, 2015, Vol. 5(4(77)), pp. 44–49. DOI: 10.15587/1729-4061.2015.50442.
8. Press S. J. Multivariate stable distributions. *Journal of Multivariate Analysis*, 1972, Vol. 2 (4), pp. 444–462. DOI: 10.1016/0047-259x(72)90038-3.
9. Balakrishnan N., Lai C. D. Continuous bivariate distributions. Springer Science & Business Media, 2009, P. 684. DOI: 10.1007/b101765.

# НЕЙРОІНФОРМАТИКА ТА ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ

## НЕЙРОІНФОРМАТИКА И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

### NEUROINFORMATICS AND INTELLIGENT SYSTEMS

УДК 004.032.26

Бодяньський Є. В.<sup>1</sup>, Дейнеко А. О.<sup>2</sup>, Куценко Я. В.<sup>3</sup><sup>1</sup>Д-р. техн. наук, науковий керівник Проблемної НДЛ АСУ, Харківський національний університет радіоелектроніки, Харків, Україна<sup>2</sup>Канд. техн. наук, науковий співробітник Проблемної НДЛ АСУ, Харківський національний університет радіоелектроніки, Харків, Україна<sup>3</sup>Аспірантка кафедри штучного інтелекту Харківського національного університету радіоелектроніки, Харків, Україна

#### ПОСЛІДОВНЕ НЕЧІТКЕ КЛАСТЕРУВАННЯ НА ОСНОВІ НЕЙРО-ФАЗЗИ ПІДХОДУ

У статті запропоновано on-line нейро-фаззі систему для вирішення задач послідовного нечіткого кластерування даних, що дозволяє опрацьовувати вектори спостережень за умов обмеженого числа даних в оброблюваній вибірці, а також алгоритм її самонавчання на основі самоорганізовної мапи Т. Когонена. Архітектура системи містить сім шарів обробки інформації і є за своєю суттю гібридом системи Ванга-Менделя та нечіткої кластерувальної самоорганізовної мережі. Запропонована система в процесі самонавчання налаштовує не лише свої параметри, але й архітектуру в on-line режимі. Для налаштування параметрів функцій належності гібридної нейро-фаззі системи введено алгоритм, що ґрунтується на використанні конкурентного навчання. У процесі навчання гібридна нейро-фаззі система налаштовує синаптичні ваги, центри і параметри ширини функцій належності. Розроблено програмне забезпечення, що реалізує запропоновану архітектуру гібридної нейро-фаззі системи. Проведено низку експериментів з дослідження властивостей запропонованої системи. Результати експериментів підтвердили те, що запропоновану систему можна використовувати для розв'язання задачі кластерування, при цьому оброблення даних відбувається в on-line режимі. Система характеризується простотою чисельної реалізації. Характерною особливістю запропонованої системи є те, що вона об'єднує в собі як навчання з вчителем, так і самонавчання.

**Ключові слова:** гібридна система, обчислювальний інтелект, нейро-фаззі система, функція належності, нечітке кластерування.

#### НОМЕНКЛАТУРА

SOM – самоорганізовна мапа Когонена;

FCM – метод нечітких С-середніх;

VLDB – надвелика база даних;

RBFN – радіально-базисні нейронні мережі;

SVM – машини опорних векторів;

FSOM – нейро-фаззі мережа Когонена;

 $x(k)$  – вектор вхідних сигналів; $\hat{x}(k)$  – оцінка вектора вхідних сигналів; $x_i(k)$  –  $i$ -та компонента вектора вхідних сигналів; $m$  – кількість кластерів; $h$  – кількість функцій належності на кожному вході; $R^n$  – простір вхідних ознак; $k$  – номер спостереження у навчальній вибірці або

момент поточного часу;

 $c_{li}$  – параметр, що визначає центр  $l$ -ї функції належності  $i$ -ї компоненти; $\sigma_i$  – параметр ширини функції належності; $\sigma_{li}$  – параметр ширини  $l$ -ї функції належності  $i$ -ї компоненти; $\mu_{li}$  – функція належності на  $i$ -му вході; $N$  – обсяг навчальної вибірки; $\tilde{f}_l$  – функція належності; $\varphi_l(k)$  – сигнал на виході третього прихованого шару; $e(k)$  – векторна похибка; $\bar{e}$  – значення скалярного критерію точності; $\|\bullet\|$  – будь-яка норма у метриці Мінковського; $w_{il}$  – значення синаптичної ваги; $W$  – матриця синаптичних ваг; $r$  – радіус сусідства; $\eta(2)$  – параметр кроку навчання на другому такті; $R^h$  – простір сигналів підвищеної розмірності; $\varphi(x)$  – сигнал на виході другого прихованого шару; $()^+$  – символ операції псевдообернення; $\beta$  – невід'ємний параметр фаззифікації, що визначає нечітку границю між різними класами;

$u_j(k)$  – рівень належності  $k$ -го спостереження до  $j$ -го кластеру;

$\tilde{c}_j^K(k)$  – параметр центру в мапі Когонена;

$P(k-1)$  – коваріаційна матриця.

## ВСТУП

У наш час підходить до опрацювання інформації, які засновані на математичному апараті обчислювального інтелекту [1–4], набули широкого розповсюдження для вирішення багатьох задач, що виникають в рамках Data Mining [5, 6], при цьому кластерування займає особливе місце [7, 8], оскільки процес пошуку рішення на основі парадигми самонавчання [9] значно складніше навчання з вчителем. Незважаючи на те, що сьогодні існує безліч алгоритмів кластерування, лише незначна їх частина може бути використана для вирішення задач Data Stream Mining [10], коли інформація подається на опрацювання по-спілку в on-line режимі. У цій ситуації доцільним є використання кластерувальних самоорганізованих нейронних мереж Т. Когонена (SOM) [11], призначених для опрацювання великих масивів даних в послідовному режимі. При цьому апріорно припускається, що внутрішня структура оброблюваних даних є такою, що відновлювані кластери взаємно не перетинаються і мають опуклу форму, що дозволяє в процесі налаштування нейронної мережі побудувати розділяючі гіперплощини, які чітко розмежовують різні класи.

Зрозуміло, що існуючі системи обчислювального інтелекту мають бути суттєво модифікованими для оброблення великих масивів інформації (Big Data), які поспілку надходять на опрацювання та формують кластери довільної форми, що можуть деяким чином перетинатися.

У зв'язку з цим метою цієї роботи є розробка гібридної еволюційної нейро-фаззі системи та адаптивного метода її самонавчання для послідовного нечіткого кластерування даних в умовах перетинання кластерів довільної форми.

## 1 ПОСТАНОВКА ЗАДАЧІ

У найбільш загальній постановці задачі кластерування передбачається, що є масив (можливо зростаючий) з  $N$  багатовимірних спостережень, що описуються  $n$ -вимірними векторами ознак  $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T \in R^n$ ,  $k = 1, 2, \dots, N, \dots$ , які необхідно розбити на  $m$  кластерів, при цьому це число може бути заздалегідь невідомо, тобто  $1 < m < N$ . Очевидно, що така велика кількість відомих методів вирішення задачі кластерування пов'язана з тим, що сьогодні не існує універсального алгоритму придатного для ефективного використання у всіх виникаючих випадках. Одна з таких можливих і досить складних ситуацій пов'язана з припущенням, що кожен вектор спостережень може одночасно відноситись з різними рівнями належності не до одного, а відразу до кількох чи до всіх формуємих кластерів. У цій ситуації на перший план виходять, так звані, м'які алгоритми (soft algorithms) [8], серед яких найбільшу увагу привернуто до нейро-фаззі систем [9–11].

## 2 ОГЛЯД ЛІТЕРАТУРИ

Задача кластерування великих масивів багатовимірних спостережень (векторів-образів) часто виникає у багатьох реальних практичних задачах, а для її вирішення розроблено множини алгоритмів [1–3], при цьому в останні роки в рамках концепції Big Data особлива увага приділяється оброблянню інформації, що зберігається або у надвеликих базах даних (VLDB), або надходить на опрацювання в on-line режимі в формі потоку даних (data stream).

У випадку, коли класи перетинаються можуть бути використані методи нечіткого кластерного аналізу [12, 13], у тому числі нечіткі самоорганізовані мережі Т. Когонена [14, 15], що реалізують в тій чи іншій формі метод нечітких  $C$ -середніх (FCM) [16].

У випадку неопуклих кластерів завдання кластерування істотно ускладнюється, оскільки нейронні мережі Т. Когонена як в чіткому, так і нечіткому варіантах, реалізують фактично методи  $K$ -середніх і нечітких  $C$ -середніх, які формують опуклі множини з опрацьованих спостережень.

Для вирішення задач кластерування у випадках, коли класи даних мають довільну форму, можуть бути використані ядерні самоорганізовані мапи Т. Когонена [7, 17, 18], побудовані на основі ядер Дж. Мерсера [19–21] і засновані на мінімізації критерію емпіричного ризику, що полягає в основі спеціального класу нейронних мереж, відомих як машини опорних векторів (SVM) [9]. Треба відзначити, що SVM-нейронні мережі, як потужний засіб вирішення багатьох задач Data Mining, включаючи і кластерування, призначені для опрацювання інформації тільки у пакетному режимі і не можуть аналізувати дані, що поспілку надходять в нейронну мережу.

У зв'язку з цим доцільно замість традиційного SVM-підходу використовувати ідеї, що покладені в основу радіально-базисних нейронних мереж (RBFN) [9] і пов'язані з теоремою Т. Кавера [23], яка стверджує, що лінійно-нероздільна задача розпізнавання образів в просторі вхідних ознак  $R^n$  може стати лінійно-роздільною в просторі підвищеної розмірності  $R^h$  ( $n+1 \leq h$ ). На основі спільного використання RBFN і SOM в [23] була введена on-line кластеризувальна нейро-система, призначена для чіткого відновлення класів довільної форми. Основним недоліком цієї системи, втім як і всіх радіально-базисних нейромереж, є, так званий, «прокльон розмірності», що породжує різке збільшення числа  $R$ -нейронів в прихованому шарі з ростом розмірності вхідного простору  $R^n$ .

У зв'язку з цим доцільною є розробка on-line нейро-фаззі системи для вирішення задач послідовного нечіткого кластерування даних, що дозволяє опрацьовувати вектори спостережень будь-якої розмірності в умовах обмеженого числа спостережень в оброблюваній вибірці.

## 3 МАТЕРІАЛИ І МЕТОДИ

На рис. 1 наведено архітектуру запропонованої гібридної кластеризувальної on-line нейро-фаззі системи. Вхідною інформацією для цієї системи є центрована щодо середнього вибірка векторів спостережень, яка можливо зростає  $x(1), x(2), \dots, x(k), \dots, x(N), \dots$ ;  $x(k) = (x_1(k), \dots, x_i(k), \dots, x_n(k))^T \in R^n$  таких, що

$-1 \leq x_i(k) \leq 1$ ,  $\frac{1}{N} \sum_{k=1}^N x_i(k) = 0$ , яка повинна бути розділена

на  $m$  кластерів довільної форми, при цьому  $k$  тут може бути як номером поточного спостереження, так і моментом поточного часу.

Вектори спостережень  $x(k)$  послідовно надходять на нульовий (рецепторний) шар системи, звідки передаються на перший прихований шар, утворений  $nh$  (по  $h$  на кожний вхід) функціями  $\mu_{li}(x_i)$ ,  $l = 1, 2, \dots, h$ ;  $i = 1, 2, \dots, n$  і виконуючий фаззифікування вхідного простору  $R^n$ . Другий прихований шар забезпечує агрегування рівнів належності, розрахованих в першому шарі, і містить  $h$  блоків множення. Таким чином, перші два шари цієї системи повністю збігаються з шарами найбільш популярних нейро-фаззі систем ANFIS і TSK [24, 25], основною перевагою яких крім універсальних апроксимуючих властивостей є те, що їх вихідний сигнал лінійно залежить від параметрів-синаптичних ваг, які налаштовуються, що дозволяє використовувати для їх налаштування як множини відомих лінійних алгоритмів навчання [9, 26], так і відомі методи адаптивного кластерування [30, 28], які є оптимальними за швидкодією.

Отже, якщо на вхід системи подано векторний сигнал  $x(k)$ , елементи першого прихованого шару здійснюють його фаззифікування, обчислюючи рівні належності  $0 < \mu_{li}(x_i(k)) \leq 1$ , при цьому зазвичай в якості функцій належності використовуються традиційні гавсіани

$$\mu_{li}(x_i(k)) = \exp\left(-\frac{(x_i(k) - c_{li})^2}{2\sigma_i^2}\right),$$

де  $c_{li}$ ,  $\sigma_i$  – параметри центрів і ширини відповідно. Зауважимо також те, що попереднє кодування даних на деякий інтервал, наприклад,  $-1 \leq x_i(k) \leq 1$  дозволяє спростити розрахунки, оскільки параметри ширини  $\sigma_i$  в цьому випадку можуть бути прийняті однаковими для всіх входів, тобто  $\sigma_i = \sigma$ .

У другому прихованому шарі обчислюються агреговані значення

$$\varphi_l(k) = \prod_{i=1}^n \mu_{li}(x_i(k)),$$

при цьому для гавсіанів з однаковими параметрами ширини є коректним співвідношення

$$\varphi_l(k) = \prod_{i=1}^n \mu_{li}(x_i(k)) = \prod_{i=1}^n \exp\left(-\frac{(x_i(k) - c_{li})^2}{2\sigma^2}\right) = \exp\left(-\frac{\|x(k) - c_l\|^2}{2\sigma^2}\right),$$

де  $c_l = (c_{l1}, c_{l2}, \dots, c_{ln})^T$ , тобто сигнали на виходах блоків множення другого прихованого шару є аналогічними сигналам на виходах нейронів  $R_l$  першого прихованого шару звичайних радіально-базисних нейронних мереж (RBFN).

Третій прихований шар системи – шар нормалізації ( $N$ ) реалізує елементарне перетворення

$$\tilde{\varphi}(x) = \frac{\varphi(x)}{\|\varphi(x)\|},$$

де  $\varphi(x) = (\varphi_1(x), \dots, \varphi_l(x), \dots, \varphi_h(x))^T$ , необхідне для ефективної роботи четвертого вихідного шару, що є фактично кластерувальною нейро-фаззі мережею Когонена (FSOM) [29], налаштування параметрів якої виконується за допомогою спеціалізованої процедури конкурентного самонавчання.

У цьому шарі вирішується задача розбиття послідовностей образів підвищеної розмірності  $\tilde{\varphi}(x(1)), \dots, \tilde{\varphi}(x(k)), \dots, \tilde{\varphi}(x(N)), \dots$  на  $m$  кластерів із знаходженням прототипів-центроїдів  $\tilde{c}_1^k, \dots, \tilde{c}_j^k, \dots, \tilde{c}_m^k$  (нейрони  $N_j^K$ ) і рівнів належності кожного  $\tilde{\varphi}(k)$  до кожного  $j$ -го кластера  $u_j(k)$  (нейрони  $N_j^M$ ),  $\tilde{c}_j^k \in R^h$ ,  $j = 1, 2, \dots, m$ .

Важлива проблема, що виникає в процесі синтезу системи, полягає в тому, як ефективно організувати базис, утворений дзвонуватими функціями, в якому можна було б ефективно провести кластерування. Для цього необхідно організувати процес адаптації кількості  $h > n$  і центрів  $c_{li}$  функцій належності першого шару.

Для вирішення цієї задачі призначені п'ятий, шостий і сьомий додаткові шари, утворені  $nh$  налаштованими синаптичними вагами,  $n+1$  суматорами і  $n$  блоками ділення, що вирішують задачі дефаззифікування.

Таким чином, перший, другий, п'ятий, шостий і сьомий шари системи утворюють по суті багатовихідну нейро-фаззі систему Ванга-Менделя [30] (TSK-система нульового порядку), основною відмінністю якої є те, що в якості навчального тут використовується вхідний сигнал  $x(k)$ , тобто система працює в режимі автоасоціації [21]. Виходом сьомого шару є векторний сигнал  $\hat{x}(k) \in R^n$ , який є оцінкою вхідного сигналу  $x(k)$ .

Якість відновлення оцінюється на основі векторної похибки

$$e(k) = x(k) - \hat{x}(k)$$

за допомогою того чи іншого скалярного критерію, наприклад:

$$\bar{e} = \frac{1}{N} \sum_{k=1}^N \frac{\|x(k) - \hat{x}(k)\|}{\|x\|^*},$$

де  $\|\bullet\|^*$  – будь-яка норма у метриці Мінковського, або МАРЕ-оцінки

$$\bar{e} = \frac{1}{N} \sum_{k=1}^N \frac{\sum_{i=1}^n |x_i(k) - \hat{x}_i(k)|}{\sum_{i=1}^n |x_i(k)|} \times 100\%.$$



Якщо виявиться, що значення  $\bar{e}$  перевищує деякий апіорно заданий поріг, приймається рішення про те, що процес налаштування цих шарів повинен тривати, тобто  $h, c_{li}, w_{il}$ , підлягають подальшому уточненню. Кінцевим результатом навчання цих шарів є значення  $h, c_{li}, i$  матриця синаптичних ваг  $W = \{w_{il}\}$ .

Необхідно також зауважити, що на виходах  $p$ 'ятого прихованого шару формується  $nh$  сигналів

$$w_{il} \prod_{i=1}^n \mu_{li}(x_i(k)) = w_{il} \phi_l(k),$$

а на виходах шостого  $-n + 1$  сигналів




Рисунок 1 – Нечітка кластерувальна гібридна нейро-фаззі система

$$\sum_{l=1}^h w_{il} \prod_{i=1}^n \mu_{li}(x_i(k)) = \sum_{l=1}^h w_{il} \varphi_l(k),$$

$$\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k)) = \sum_{l=1}^h \varphi_l(k)$$

і, нарешті, на виходах сьомого шару –  $n$  сигналів

$$\begin{aligned} \hat{x}_i(k) &= \frac{\sum_{l=1}^h w_{il} \prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} = \sum_{l=1}^h w_{il} \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} = \\ &= \sum_{l=1}^h w_{il} \hat{\varphi}_l(x(k)) = w_i^T \hat{\varphi}^h(x(k)), \end{aligned}$$

$$\text{де } \hat{\varphi}_l(x(k)) = \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))}, \quad w_i = (w_{i1}, w_{i2}, \dots, w_{ih})^T,$$

$$(\hat{\varphi}_1(x(k)), \dots, \hat{\varphi}_1(x(k)), \dots, \hat{\varphi}_h(x(k)))^T.$$

Вводячи в подальший розгляд  $(n \times 1)$ -вектор  $\hat{x}(k) = (\hat{x}_1(k), \dots, \hat{x}_i(k), \dots, \hat{x}_n(k))^T$  і  $(n \times h)$ -матрицю  $W = (w_1, w_i, \dots, w_n)^T$ , остаточно можна записати

$$\hat{x}(k) = W \hat{\varphi}^h(x(k))$$

та

$$e(k) = x(k) - W \hat{\varphi}^h(x(k)).$$

Процес навчання нейро-фаззі системи, що розглядається, зводиться до самонавчання – еволюції першого прихованого шару, навчання з вчителем матриці синаптичних ваг  $w$  п'ятого прихованого шару і конкурентного самонавчання нейро-фаззі-мережі Когонена четвертого вихідного шару.

В основу налаштування першого прихованого шару покладені ідеї еволюційних фаззі-систем і, перш за все, адаптивний метод самонавчання гібридної нейро-фаззі системи [31].

Нехай на вхід системи, у якій в початковому стані в першому прихованому шарі відсутні функції належності, надходить перше спостереження навчальної вибірки  $x(1) = (x_1(1), \dots, x_i(1), \dots, x_n(1))^T$ . Це спостереження формує перший набір функцій належності  $\mu_1 = (\mu_{11}, \dots, \mu_{1i}, \dots, \mu_{1n})^T$  таких, що  $c_{1i} = x_i(1)$ .

Далі для векторної функції належності  $\mu_1$  з центром  $c_1(1)$  задається радіус сусідства  $r$ , що визначається максимально можливим числом  $h$  функцій належності у системі. Так, якщо функції належності по компонентам роз-

поділені рівномірно, то

$$r = \frac{2}{h-1}.$$

Далі, при надходженні другого спостереження  $x(2)$  проводиться перевірка умови

$$\max_i |c_{1i} - x_i(2)| \leq r. \quad (1)$$

Якщо ця умова виконується, проводиться корекція центрів функцій належності  $\mu_1$  відповідно до правила

$$c_{1i}(2) = c_{1i}(1) + \eta(2)(x_i(2) - c_{1i}(1)),$$

де  $\eta(2)$  – параметр кроку навчання, наприклад, при  $\eta(2) = 0,5$

$$c_{1i}(2) = \frac{c_{1i}(1) + x_i(2)}{2}.$$

У тому випадку, якщо умова (1) не виконується, формується друга функція належності з центрами

$$c_{2i}(2) = x_i(2).$$

Таким чином, формується вузол системи  $R_2$ , утворений елементами першого і другого шарів.

Нехай до моменту надходження на вхід системи спостереження  $x(k)$  сформовано  $p$  вузлів  $R_l$  функцій належності  $\mu_1, \mu_2, \dots, \mu_p, p < h$  з центрами  $c_{li}(k-1), l = 1, 2, \dots, p; i = 1, 2, \dots, n$ . З надходженням  $x(k)$  виконується перевірка умови

$$\max_i |c_{1i} - x_i(k)| \leq r \quad \forall l = 1, 2, \dots, p. \quad (2)$$

Якщо ця умова виконується, проводиться корекція центрів функцій належності, найближчих до відповідних компонентів  $x_i(k)$  відповідно до правила

$$c_{li}(k) = c_{li}(k-1) + \eta(k)(x_i(k) - c_{li}(k-1)). \quad (3)$$

Нескладно помітити, що (3) є не що інше, як відоме правило самонавчання Т. Когонена «Переможець отримує все» [11] з тією лише різницею, що самонавчання мапи Т. Когонена реалізується на гіперсфері

$$\|x(k)\|_2 = 1,$$

а правило (3) – на гіперкубі

$$\|x(k)\|_\infty = 1.$$

У тому випадку, якщо умова (2) не виконується, в системі формується  $(p+1)$ -й  $(p+1 \leq h)$  вузол  $R_{p+1}$  з центрами функцій належності

$$c_{p+1,i}(k) = x_i(k).$$

Як можна побачити, ця процедура є гібридом еволюційного алгоритму Н. Касабова [33] і самоорганізовної мапи Т. Когонена [11], при цьому процес еволюції архітектури-самонавчання функцій належності може протікати як безперервно, так і до досягнення кількості функцій належності граничного значення  $nh$ .

Для налаштування матриці синаптичних ваг може бути використаний або рекурентний метод найменших квадратів, який є за суттю оптимальною за швидкістю гавсієвсько-ньютонівською процедурою оптимізації вигляду

$$\begin{cases} W(k) = W(k-1) + \frac{(x(k) - W(k-1)\hat{\phi}^h(x(k)))\hat{\phi}^{hT}(x(k))P(k-1)}{1 + \hat{\phi}^{hT}(x(k))P(k-1)\hat{\phi}^h(x(k))}, \\ P(k) = P(k-1) - \frac{P(k-1)\hat{\phi}^h(x(k))\hat{\phi}^{hT}(x(k))P(k-1)}{1 + \hat{\phi}^{hT}(x(k))P(k-1)\hat{\phi}^h(x(k))}, \end{cases}$$

або багатовимірна версія алгоритму Качмажа-Уїдрю-Гоффа

$$\begin{aligned} W(k) &= W(k-1) + \frac{(x(k) - W(k-1)\hat{\phi}^h(x(k)))\hat{\phi}^{hT}(x(k))}{\|\hat{\phi}^h(x(k))\|^2} \hat{\phi}^{hT}(x(k)) = \\ &= W(k-1) + (x(k) - W(k-1)\hat{\phi}^h(x(k)))\hat{\phi}^{h+}(x(k)), \end{aligned}$$

де  $(\bullet)^+$  – символ операції псевдообернення.

В основі конкурентного самонавчання четвертого прихованого шару полягає ймовірнісний алгоритм нечіткого кластерування, заснований на оптимізації цільової функції вигляду [16]

$$E(u_i, \tilde{c}_j^K) = \sum_{k=1}^N \sum_{j=1}^m u_j^K(k) \|\tilde{\varphi}(x(k)) - \tilde{c}_j^K\|^2$$

за обмежень

$$\begin{aligned} \sum_{j=1}^m u_j(k) &= 1, k = 1, 2, \dots, N, \\ 0 \leq \sum_{k=1}^N u_j(k) &\leq N, j = 1, 2, \dots, m, \end{aligned}$$

де  $u_j(k) \in [0, 1]$ ,  $\beta$  – невід’ємний параметр фаззифікування, що визначає нечітку границю між різними класами і впливає на рівень нечіткості в остаточному розбитті даних по кластерам.

Застосування стандартного апарату нелінійного програмування, заснованого на невизначених множниках Лагранжа і вирішенні системи рівнянь Каруша-Куна-Таккера, веде до відомого результату

$$\begin{cases} \tilde{c}_j^K = \frac{\sum_{k=1}^N u_j^K(k) \tilde{\varphi}(x(k))}{\sum_{k=1}^N u_j^K(k)}, \\ u_j(k) = \frac{\left(\|\tilde{\varphi}(x(k)) - \tilde{c}_j^K\|^2\right)^{\frac{1}{1-\beta}}}{\sum_{l=1}^m \left(\|\tilde{\varphi}(x(k)) - \tilde{c}_l^K\|^2\right)^{\frac{1}{1-\beta}}}, \end{cases} \quad (4)$$

який при  $\beta = 2$  збігається з алгоритмом нечітких С-середніх (FCM) Дж. Бездека:

$$\begin{cases} \tilde{c}_j^K = \frac{\sum_{k=1}^N u_j^2(k) \tilde{\varphi}(x(k))}{\sum_{k=1}^N u_j^2(k)}, \\ u_j(k) = \frac{\left(\|\tilde{\varphi}(x(k)) - \tilde{c}_j^K\|^2\right)^{-2}}{\sum_{l=1}^m \left(\|\tilde{\varphi}(x(k)) - \tilde{c}_l^K\|^2\right)^{-2}}. \end{cases} \quad (5)$$

Алгоритми (4), (5) набули широкого поширення при вирішенні задач нечіткого кластерування, проте їх використання можливе тільки в пакетному режимі при фіксованому об’ємі оброблюваної вибірки даних.

Якщо ж дані надходять на опрацювання послідовно в on-line режимі, є доцільним використання рекурентного варіанту (4), заснованого на процедурі нелінійного програмування Ерроу-Гурвіца-Удзави вигляду

$$\begin{cases} \tilde{c}_j^K(k) = \tilde{c}_j^K(k-1) + \eta(k) u_j^\beta(k-1) (\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k-1)), j = 1, 2, \dots, m, \\ u_j(k) = \frac{\left(\|\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k)\right)^{\frac{1}{1-\beta}}}{\sum_{l=1}^m \left(\|\tilde{\varphi}(x(k)) - \tilde{c}_l^K(k)\right)^{\frac{1}{1-\beta}}}. \end{cases} \quad (6)$$

Аналізуючи (6), можна помітити, що розглядаючи співмножник  $u_j^\beta(k-1)$  в якості функції сусідства, отримуємо правило самонавчання Т. Когонена на основі принципу «Переможець отримує більше» (WTM), при  $\beta \rightarrow 1$  отримуємо алгоритм типу К-середніх, а  $\beta \rightarrow 0$  відповідає стандартному правилу Т. Когонена типу «Переможець отримує все» (WTA):

$$\tilde{c}_j^K(k) = \tilde{c}_j^K(k-1) + \eta(k) (\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k-1)) \quad (7)$$

аналогічне (3). Нескладно помітити також, що рекурентна процедура (7) мінімізує цільову функцію вигляду

$$E(\tilde{c}_j^K) = \sum_k \|\tilde{\varphi}(x(k)) - \tilde{c}_j^K\|^2,$$

оптимізація якої веде до звичайної оцінки середнього арифметичного

$$\tilde{c}_j^K(k) = \frac{1}{k} \sum_{\varphi(\tilde{x}(k)) \in Cl_j} \tilde{\varphi}(x(k))$$

або у рекурентній формі:

$$\tilde{c}_j^K(k) = \tilde{c}_j^K(k-1) + \frac{1}{k} (\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k-1)).$$

Такий вибір параметра кроку  $\eta(k)$  узгоджується з правилами стохастичної апроксимації і надає результатам ясний фізичний зміст.

Таким чином, алгоритм самонавчання (6) четвертого прихованого шару остаточно може бути записаний у вигляді

$$\left\{ \begin{aligned} \tilde{c}_j^K(k) &= \tilde{c}_j^K(k-1) + \frac{u_j^\beta(k-1)}{k} (\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k-1)), j = 1, 2, \dots, m, \\ u_j(k) &= \frac{\left( \|\tilde{\varphi}(x(k)) - \tilde{c}_j^K(k)\|^2 \right)^{\frac{1}{1-\beta}}}{\sum_{l=1}^m \left( \|\tilde{\varphi}(x(k)) - \tilde{c}_l^K(k)\|^2 \right)^{\frac{1}{1-\beta}}}, \end{aligned} \right.$$

що поєднує в собі обчислювальну простоту і послідовну обробку когоненівського навчання з можливістю нечіткого кластерування.

Вектори-центроїди кластерів  $\tilde{c}_j^K(k)$ , обчислені в просторі підвищеної розмірності  $R^h$ , далі можуть бути спроектовані у вихідний простір  $R^n$  за допомогою матриці синаптичних ваг на основі перетворення

$$c_j^K(k) = W(k)^N \tilde{c}_j^K(k) \quad \forall j = 1, 2, \dots, m,$$

$$c_j^K(k) \in R^n, \quad \tilde{c}_j^K(k) \in R^h.$$

Таким чином, розглянута кластерувальна нейро-фаззі система є за суттю гібридом двох нейро-фаззі систем: еволюційної TSK-системи і нечіткої кластерувальної мережі Когонена, що дозволяє в on-line режимі відновлювати класи довільної форми, що перекриваються (лінійно нероздільні), які формуються даними, що надходять на оброблення у формі потоку інформації.

#### 4 ЕКСПЕРИМЕНТИ

Ефективність запропонованої гібридної нейро-фаззі системи та процедур її навчання продемонстрована при розв'язанні задачі нечіткого кластерування. В якості тестових даних було обрано три вибірки з UCI-репозиторія – Iris, Wine та Breast Cancer [34]. Всі данні було попередньо пронормовано на гіперкуб в інтервалі  $[-1, 1]$ .

Для порівняння ефективності запропонованої системи з ефективністю інших існуючих систем було обрано самоорганізовану мапу Т. Когонена та метод нечітких С-середніх (FCM).

У якості критерію якості кластерування було обрано середньоквадратичну похибку MSE.

#### 5 РЕЗУЛЬТАТИ

Результати проведених експериментів наведено в табл. 1.

Таблиця 1 – Результати експериментів

Тип системи	Iris	Wine	Breast Cancer
Самоорганізована мапа Т. Когонена	0,067	0,79	0,82
FCM	0,07	0,072	0,08
Гібридна нейро-фаззі система	0,054	0,069	0,0083

#### 6 ОБГОВОРЕННЯ

Як можна побачити з табл. 1, запропонована гібридна нейро-фаззі система досить непогано показала себе при розв'язанні задач кластерування. Варто відзначити, що з ростом вибірки похибка кластерування запропонованої нейро-фаззі системи зменшувалась. Якщо порівнювати якість кластерування, гібридна нейро-фаззі система продемонструвала найкращий результат.

Результат кластерування за допомогою гібридної нейро-фаззі системи для вибірок Iris, Wine та Breast Cancer наведено на рис. 2. Для більшої наочності результати візуалізовані у трьохвимірному просторі.




Рисунок 2 – Результати кластерування гібридною нейро-фаззі системою: а – вибірка Iris, б – вибірка Wine, в – вибірка Breast Cancer

## ВИСНОВКИ

Таким чином у розгляд введено еволюційний підхід до вирішення задач нечіткого on-line кластерування потоків даних, що послідовно надходять на опрацювання.

Наукова новизна роботи полягає у тому, що запропоновано гібридну нейро-фаззі систему обчислювального інтелекту, що призначена для нечіткого on-line кластерування потоку інформації в умовах невизначеності як про форму класів, так і про рівні їх перекриття. Введена нейро-фаззі система є досить простою в чисельній реалізації і дозволяє вирішувати задачі динамічного інтелектуального аналізу даних (DDM) та інтелектуального аналізу потоків даних (DSM) за умов суттєвої апріорної невизначеності.

До практичної цінності отриманих результатів можна віднести те, що запропоновану систему можна використовувати для розв'язання задач кластерування в умовах великої кількості спостережень (Big Data), що надходять на оброблення в послідовному режимі.

## ПОДЯКИ

Роботу виконано в рамках держбюджетної науково-дослідної теми Харківського національного університету радіоелектроніки № 307 «Динамічний інтелектуальний аналіз послідовностей нечіткої інформації за умов суттєвої невизначеності на основі гібридних систем обчислювального інтелекту».

## СПИСОК ЛІТЕРАТУРИ

1. Rutkowski L. Computational Intelligence. Methods and Techniques / L. Rutkowski. – Berlin-Heidelberg : Springer-Verlag, 2008. – 514 p.
2. Mumford C. Computational Intelligence. Collaboration, Fuzzy and Emergence / C. Mumford, L. Jain. – Berlin: Springer-Verlag, 2009. – 726 p.
3. Computational Intelligence. A Methodological Introduction / [R. Kruse, C. Borgelt, F. Klawonn and other]. – Berlin : Springer, 2013. – 488 p.
4. Du K.-L. Neural Networks and Statistical Learning / K.-L. Du, M. N. S. Swamy. – London : Springer-Verlag, 2014. – 824 p.
5. Han J. Data Mining : Concepts and Techniques / J. Han, M. Kamber. – Amsterdam : Morgan Kaufmann Publ., 2006. – 754 p.
6. Aggarwal C. C. Data Mining / A. A. Aggarwal. – Cham : Springer, Int. Publ., Switzerland, 2015. – 734 p.
7. Aggarwal C. C. Data Clustering. Algorithms and Application / C. C. Aggarwal, C. K. Reddy. – Boca Raton : CRC Press, 2014. – 648 p.
8. Xu R. Clustering, IEEE Press Series on Computational Intelligence / R. Xu, D. C. Wunsch. – Hoboken, NJ: John Wiley & Sons, Inc., 2009. – 370 p.
9. Haykin S. Neural Networks. A Comprehensive Foundation / S. Haykin. – Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. – 842 p.
10. Bifet A. Adaptive Stream Mining: Pattern Learning and Mining from Evolving Data Streams / A. Bifet. – IOS Press, 2010. – 224 p.
11. Kohonen, T. Self-Organizing Maps / T. Kohonen. – Berlin : Springer-Verlag, 1995. – 362 p.
12. Höppner F. Fuzzy-Clusteranalyse. Verfahren für die Bilderkennung, Klassifikation und Datenanalyse. / F. Höppner, F. Klawonn, R. Kruse. – Braunschweig : Vieweg, 1996. – 280 p.
13. Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition [F. Höppner, F. Klawonn, R. Kruse, T. Runkler]. – Chichester : John Wiley & Sons, 1999. – 289 p.
14. Tsao E. C.-K. Fuzzy Kohonen clustering networks / E. C.-K. Tsao, J. C. Bezdek, N. R. Pal // Pattern Recognition. – 1994. – Vol. 27, № 5. – P. 757–764.
15. Smoothly distributed fuzzy C-means: a new self-organizing map [R. D. Pascual-Marqui, A. D. Pascual-Montano, K. Kochi, J. M. Caroso] // Pattern Recognition, 2001. – Vol. 34, № 5. – P. 2395–2402.
16. Bezdek J.-C. Pattern Recognition with Fuzzy Objective Function Algorithms / J.-C. Bezdek. – N. Y. : Plenum Press, 1981. – 272 p.
17. Girolami M. Mercer kernel-based clustering in feature space / M. Girolami // IEEE Transactions on Neural Networks. – 2002. – Vol. 13, Issue 3. – P. 780–784.
18. Camastra F. A novel kernel method for clustering / F. Camastra, A. Verri // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2005. – Issue. 5. – P. 801–805.
19. Schölkopf B. Learning with Kernels / B. Schölkopf, A. Smola. – Cambridge, M. A. : MIT Press, 2002. – 648 p.
20. Kung S. Y. Kernel Methods and Machine Learning / S. Y. Kung. – Cambridge : University Press, 2014. – 578 p.
21. Kacprzyk J. Springer Handbook of Computational Intelligence / J. Kacprzyk, W. Pedrycz. – Berlin Heidelberg : Springer-Verlag, 2015. – 1634 p.
22. Cover T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition / T. M. Cover // IEEE Transactions on Electronic Computers. – 1965. – Vol. 14. – P. 326–334.
23. Бодянский Е. В. Ядерная самоорганизующаяся карта на основе радиально-базисной нейронной сети / Е. В. Бодянский, А. А. Дейнеко, Я. В. Куценко // Электротехнические и компьютерные системы. – 2015. – № 20. – С. 97–105.
24. Jang J.-S. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence / J.-S. Jang, C.-T. Sun, E. Mizutani. – Upper Saddle River: Prentice Hall, 1997. – 640 p.
25. Takagi T. Fuzzy identification of systems and its applications to modeling and control / T. Takagi, M. Sugeno // IEEE Transactions on Systems, Man, and Cybernetics. – 1985. – Vol. 15, № 1. – P. 116–132.
26. Friedman J. The Elements of Statistical Learning. Data Mining, Inference and Prediction / J. Friedman, T. Hasti, R. Tibshirani. – Berlin : Springer, 2003. – 552 p.
27. Ljung L. System Identification : Theory for User / L. Ljung. – Upper Saddle river : Prentice Hall, Inc., 1987. – 432 p.
28. Nelles O. Nonlinear System Identification / O. Nelles. – Berlin : Springer, 2001. – 785 p.
29. Bodyanskiy Ye. Adaptive neuro-fuzzy Kohonen network with variable fuzzifier / Ye. Bodyanskiy, B. Kolchygin, I. Pliss // Int. J. Information Technologies and Knowledge. – 2011. – Vol. 18, Issue 3. – P. 215–223.
30. Wang L. X. Fuzzy basis functions, universal approximation, and orthogonal least-squares learning / L. X. Wang, J. M. Mendel // IEEE Transactions on Neural Networks. – 1992. – Vol. 3, Issue 5. – P. 807–814.
31. Lughofer E. Evolving Fuzzy Systems – Methodologies and Applications / E. Lughofer. – Studies in Fuzziness and Soft Computing. – Springer-Berlin, 2011. – 410 p.
32. Bodyanskiy Ye. V. Adaptive method of hybrid learning for an evolving neuro-fuzzy system / Ye. V. Bodyanskiy, O. O. Boiko, I. P. Pliss // Cybernetics and Systems Analysis. – 2015. – Vol. 51, Issue 4. – P. 500–505.
33. Kasabov N. Evolving Connectionist Systems / N. Kasabov. – London : Springer-Verlag, 2003. – 307 p.
34. Frank A. UCI Machine Learning Repository [Electronic resource] / A. Frank, A. Asuncion. – Irvine, CA : University of California, School of Information and Computer Science, 2013. – Access mode: <http://archive.ics.uci.edu/ml>.

Стаття надійшла до редакції 01.08.2016.

Після доробки 16.08.2016.

Бодянский Е. В.<sup>1</sup>, Дейнеко А. О.<sup>2</sup>, Куценко Я. В.<sup>3</sup>

<sup>1</sup>Д-р техн. наук, научный руководитель Проблемной НИЛ АСУ, Харьковский национальный университет радиоэлектроники, Харьков, Украина

<sup>2</sup>Канд. техн. наук, научный сотрудник Проблемной НИЛ АСУ, Харьковский национальный университет радиоэлектроники, Харьков, Украина

<sup>3</sup>Аспирантка кафедры искусственного интеллекта Харьковского национального университета радиоэлектроники, Харьков, Украина

#### ПОСЛЕДОВАТЕЛЬНАЯ НЕЧЕТКАЯ КЛАСТЕРИЗАЦИЯ НА ОСНОВЕ НЕЙРО-ФАЗЗИ ПОДХОДА

В статье предложена on-line нейро-фаззи система для решения задачи последовательной нечеткой кластеризации данных, которая позволяет обрабатывать векторы наблюдений любой размерности в условиях ограниченного числа данных в обрабатываемой выборке, а также алгоритм ее самообучения на основе самоорганизующейся карты Т. Кохонена. Архитектура системы содержит семь слоев обработки информации и, по своей сути, является гибридом системы Ванга-Менделя и кластеризирующей самоорганизующейся сети. Предложенная система в процессе самообучения настраивает не только свои параметры, но и архитектуру в on-line режиме. Для настройки параметров функций принадлежности гибридной нейро-фаззи системы введен алгоритм, основанный на использовании конкурентного обучения. В процессе обучения гибридная нейро-фаззи система настраивает синаптические веса, центры и параметры ширины функций принадлежности. Разработано программное обеспечение, реализующее предложенную архитектуру гибридной нейро-фаззи системы. Проведен ряд экспериментов по исследованию свойств предлагаемой системы. Результаты экспериментов подтвердили, что предложенную систему можно использовать для решения задачи кластеризации, при этом обработка данных происходит в on-line режиме. Система характеризуется простотой численной реализации. Отличительной особенностью предложенной системы является то, что она объединяет в себе как обучение с учителем, так и самообучение.

**Ключевые слова:** гибридная система, вычислительный интеллект, нейро-фаззи система, функция принадлежности, нечеткая кластеризация.

Bodyanskiy Ye. V.<sup>1</sup>, Deineko A. O.<sup>2</sup>, Kutsenko Ya. V.<sup>3</sup>

<sup>1</sup>Dr. Sc., Scientific Head of the Control Systems Research Laboratory, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

<sup>2</sup>Ph.D, Researcher at the Control Systems Research Laboratory, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

<sup>3</sup>Ph.D, student at the Artificial Intelligence Department, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

#### SEQUENTIAL FUZZY CLUSTERING BASED ON NEURO-FUZZY APPROACH

An on-line neuro-fuzzy system for solving data stream fuzzy clustering task and its self-learning procedures based on T. Kohonen's rule are proposed in the paper. The architecture of proposed system consists of seven information processing layers and represents the hybrid of the Wang-Mendel system and clustering self-organizing network. During a learning procedure in on-line mode, the proposed system tunes both its parameters and its architecture. For tuning of membership functions parameters of neuro-fuzzy system the method based on competitive learning is proposed. The hybrid neuro-fuzzy system tunes its synaptic weights, centers and width parameters of membership functions. Software that implements the proposed hybrid neuro-fuzzy system's architecture has been developed. A number of experiments has been held in order to research the proposed system's properties. Experimental results have proved the fact that the proposed system could be used to solve a sequential stream clustering task. The proposed system provides computational simplicity. A distinguishing feature of the proposed system is that this system combine supervised learning and self-learning procedures.

**Keywords:** hybrid system, Data Mining, Data Stream Mining, neuro-fuzzy system, membership function, fuzzy clustering.

#### REFERENCES

- Rutkowski L. Computational Intelligence. Methods and Techniques. Berlin-Heidelberg, Springer-Verlag, 2008, 514 p.
- Mumford C., Jain L. Computational Intelligence. Collaboration, Fuzzy and Emergence. Berlin, Springer-Verlag, 2009, 726 p.
- Kruse R., Borgelt C., Klawonn F., Moewes C., Steinbrecher M., Held P. Computational Intelligence. A Methodological Introduction. Berlin, Springer, 2013, 488 p.
- Du K.-L., Swamy M.N.S. Neural Networks and Statistical Learning. London, Springer-Verlag, 2014, 824 p.
- Han J., Kamber M. Data Mining: Concepts and Techniques. Amsterdam: Morgan Kaufmann Publ., 2006, 754 p.
- Aggarwal C. C. Data Mining, Cham, Springer, Int. Publ., Switzerland, 2015, 734 p.
- Aggarwal C. C., Reddy C. K. Data Clustering. Algorithms and Application. Boca Raton, CRC Press, 2014, 648 p.
- Xu R., Wunsch D. C. Clustering, IEEE Press Series on Computational Intelligence. Hoboken, NJ. John Wiley & Sons, Inc., 2009, 370 p.
- Haykin S. Neural Networks. A Comprehensive Foundation, Upper Saddle River, N.J., Prentice Hall, Inc., 1999, 842 p.
- Bifet A. Adaptive Stream Mining: Pattern Learning and Mining from Evolving Data Streams. IOS Press, 2010, 224 p.
- Kohonen T. Self-Organizing Maps. Berlin, Springer-Verlag, 1995, 362 p.
- Höppner F., Klawonn F., Kruse R. Fuzzy-Clusteranalyse: Verfahren für die Bilderkennung, Klassifikation und Datenanalyse. Braunschweig, Vieweg, 1996, 280 p.
- Höppner F., Klawonn F., Kruse R., Runkler T. Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition. Chichester, John Wiley & Sons, 1999, 289 p.
- Tsao E. C.-K., Bezdek J. C., Pal N. R. Fuzzy Kohonen clustering networks, Pattern Recognition, 1994, Vol. 27, No. 5, pp. 757–764.
- Pascual-Marqui R. D., Pascual-Montano A. D., Kochi K., Caroso J. M. Smoothly distributed fuzzy C-means: a new self-organizing map, Pattern Recognition, 2001, Vol. 34, No. 5, pp. 2395–2402.
- Bezdek J.-C. Pattern Recognition with Fuzzy Objective Function Algorithms, N.Y., Plenum Press, 1981, 272 p.
- Girolami M. Mercer kernel-based clustering in feature space, IEEE Transactions on Neural Networks, 2002, Vol. 13, Issue 3, pp. 780–784.
- Camasta F., Verri A. A novel kernel method for clustering, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, Issue. 5, pp. 801–805.
- Schulkopf B., Smola A. Learning with Kernels, Cambridge, M.A., MIT Press, 2002, 648 p.
- Kung S. Y. Kernel Methods and Machine Learning, Cambridge, University Press, 2014, 578 p.
- Kacprzyk J., Pedrycz W. Springer Handbook of Computational Intelligence. Berlin Heidelberg, Springer-Verlag, 2015, 1634 p.
- Cover T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition, IEEE Transactions on Electronic Computers, 1965, Vol. 14, pp. 326–334.
- Bodyanskiy Ye., Deineko A., Kutsenko Ya. Kernel Self-Organizing Map based on radial-basis neural network, Electrotechnical and computer systems, 2015, Vol. 20, pp. 97–105.
- Jang J.-S., Sun C.-T., Mizutani E. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Upper Saddle River, Prentice Hall, 1997, 640 p.
- Takagi T., Sugeno M. Fuzzy identification of systems and its applications to modeling and control, IEEE Transactions on Systems, Man, and Cybernetics, 1985, Vol.15, № 1, pp. 116–132.
- Friedman J., Hasti T., Tibshirani R. The Elements of Statistical Learning. Data Mining, Inference and Prediction. Berlin, Springer, 2003, 552 p.
- Ljung L. System Identification: Theory for User, Upper Saddle river, Prentice Hall, Inc., 1987, 432 p.
- Nelles O. Nonlinear System Identification. Berlin, Springer, 2001, 785 p.
- Bodyanskiy Ye., Kolchygin B., Pliss I. Adaptive neuro-fuzzy Kohonen network with variable fuzzifier, Int. J. Information Technologies and Knowledge, 2011, Vol. 18, Issue 3, pp. 215–223.
- Wang L. X., Mendel J. M. Fuzzy basis functions, universal approximation, and orthogonal least-squares learning, IEEE Transactions on Neural Networks, 1992, Vol. 3, Issue 5, pp. 807–814.
- Lughofer E. Evolving Fuzzy Systems – Methodologies and Applications, Studies in Fuzziness and Soft Computing, Springer-Berlin, 2011, 410 p.
- Bodyanskiy Ye.V., Boiko O.O., Pliss I. P. Adaptive method of hybrid learning for an evolving neuro-fuzzy system, Cybernetics and Systems Analysis, 2015, Vol. 51, Issue 4, pp. 500–505.
- Kasabov N. Evolving Connectionist Systems. London, Springer-Verlag, 2003, 307 p.
- Frank A., Asuncion A. UCI Machine Learning Repository [Electronic resource], Irvine, CA, University of California, School of Information and Computer Science, 2013, Access mode: <http://archive.ics.uci.edu/ml>.

УДК 004.932.2:004.93'1

Гороховатский В. А.<sup>1</sup>, Гороховатский А. В.<sup>2</sup>, Берестовский А. Е.<sup>3</sup>

<sup>1</sup>Д-р техн. наук, профессор, профессор кафедры информационных технологий, Харьковский учебно-научный институт государственного высшего учебного заведения «Университет банковского дела», Харьков, Украина

<sup>2</sup>Канд. техн. наук, доцент, доцент кафедры информатики и компьютерной техники, Харьковский национальный экономический университет имени Семена Кузнеца, Харьков, Украина

<sup>3</sup>Аспирант кафедры информатики, Харьковский национальный университет радиоэлектроники, Харьков, Украина

## СТРУКТУРНОЕ РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ С ПРИМЕНЕНИЕМ МОДЕЛЕЙ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ И САМООРГАНИЗАЦИИ ПРИЗНАКОВ

Статья посвящена исследованию проблемы распознавания изображений в компьютерном зрении на основе множества структурных SURF-признаков. В пространстве структурных признаков выполнена самоорганизация с целью увеличения быстродействия процесса распознавания. В качестве аппарата самоорганизации использована нейронная сеть Кохонена.

Объектом исследования есть метод вычисления подобия описаний и модели интеллектуальной обработки в новом пространстве признаков. Предметом исследования является систематизация и группирование множеств структурных признаков визуальных объектов.

Цель работы – построение метода структурного распознавания с применением входных данных в виде множества кластеров структурных признаков, полученных в результате самоорганизации. Задачами исследования есть изучение особенностей и анализ моделей для вычисления характеристик кластеров, построение модифицированных мер структурного подобия, экспериментальное оценивание качества распознавания для разных способов сопоставления описаний в прикладной базе визуальных образцов.

Предложено построение метода распознавания изображений на основе эталонных описаний в кластерном виде, а распознавание базируется на классификации структурных признаков объекта в пространстве кластеров с дальнейшим вычислением и оптимизацией подобия векторных описаний.

Проведено моделирование и экспериментальные исследования предложенного метода распознавания на тестовом множестве изображений с применением признаков SURF. Подтверждена работоспособность и эффективность метода в плане быстродействия, получены оценки качества распознавания для разнообразия вариантов обработки.

**Ключевые слова:** компьютерное зрение, структурное распознавание изображений, характерные признаки, дескрипторы, структурное описание, метод SURF, самоорганизация, кластеризация, сеть Кохонена, подобие векторных описаний, матрица характеристик кластеров.

### НОМЕНКЛАТУРА

SURF – Speeded up robust features (ускоренное выделение устойчивых особенностей);

ХП – характерный признак;

$Z \subset R^n$  – описание объекта;

$\{Z^j\}_{j=1}^J$  – множество (база) эталонных описаний;

$s_j = \text{card}(Z^j)$  – число элементов эталона  $Z^j$ ;

$C_i$  – множество кластеров ХП;

$q$  – число кластеров;

$m_i$  – объем  $i$ -ого кластера;

$T = \{\{t_i^j\}_{j=1, \dots, J}\}_{i=1, \dots, q}$  – матрица характеристик кластеров;

$L[T]$  – интеллектуальная обработка матрицы  $T$ ;

$\{c_1, c_2, \dots, c_q\}$  – множество центров кластеров;

$\rho(c_a, z)$  – расстояние до центра  $c_a$  кластера с номером  $a = \overline{1, q}$ ;

$J$  – множество номеров классов;

$V_u$  – сформированное из  $u$  элементов подмножество номеров кластеров или классов;  $M = \{1, 2, \dots\}$  – ограниченное множество целых чисел;

$Ind$  – процедура индексирования по множеству  $A$  (значения  $t_i^j$  или расстояния до центров кластеров);

$\mu$  – мера подобия;

$\mu_{\max 2}$  – второй элемент в списке ранжированных по убыванию значений  $\mu$  для эталонов;

$t_i[\cdot]$  – векторное кластерное представление объекта и эталона, соответствующее строке матрицы данных  $T$ ;

$\gamma$  – нормированный коэффициент корреляции.

### ВВЕДЕНИЕ

В структурных методах распознавания изображений, получивших распространение в системах компьютерного зрения, описание визуального объекта представляют множеством характерных признаков (ХП) – векторов, закрепленных в координатах ключевых точек изображения и инвариантных к геометрическим преобразованиям объектов в поле зрения [1–4]. Это множество однотипных признаков отражает конструкцию образа объекта в виде списка точек пространства векторов. Углубленное исследование пространства структурных признаков показывает, что влияние ХП на результат распознавания напрямую зависит от их взаимосвязей в рамках описания, характеризующих подобием внутри эталона и между разнообразием описаний списка эталонов.

Ценные для распознавания параметры признаков вычисляются путем обучения в соответствии с процедурой, базирующейся на степени их взаимного подобия в пределах топологической окрестности элемента многомерного пространства. Другим способом установления параметров связи может быть экспертное оценивание составляющих множества ХП, включающее взаимное пространственное расположение и значимость для распознавания.

### 1 ПОСТАНОВКА ЗАДАЧИ

Возникает целесообразность создания и применения таких интеллектуальных моделей обработки данных в структурном распознавании, где сопоставление признаков осуществляется с учетом полученных в результате самоорганизации параметров, отражающих их ключевые свойства: взаимосвязь, взаимное влияние, близость в признаковом пространстве, значимость и действие на результат. Параметры моделей определяются эталонным множеством и схемами обработки, они способны перестраиваться путем самообучения системы при необходимости обновления базы изображений.

Целью статьи есть изучение и оценивание эффективности применения самоорганизации и интеллектуальной обработки в методах структурного распознавания в плане построения правил принятия решений о классе объектов на основе данных прикладной базы изображений. За счет самоорганизации множество структурных элементов преобразуется к вектору, что сокращает объем вычислительных затрат и повышает быстродействие распознавания.

Задачи исследования – изучение особенностей и анализ вариантов вычисления характеристик, а также построение мер структурного подобия применительно к описаниям изображений в виде множеств дескрипторов структурных признаков, а также экспериментальное оценивание качества распознавания в прикладной базе визуальных образцов.

### 2 ОБЗОР ЛИТЕРАТУРЫ

Применение самоорганизации для системы структурных признаков путем кластерного представления в рамках множества элементов базы эталонных образов на этапе обучения позволяет вскрыть внутреннюю структуру признакового пространства и свести распознавание к значительно более эффективному сопоставлению, где эталоны описываются векторами, а релевантность эталону характеризуется числовым коэффициентом, имеющим смысл функции принадлежности [1–4].

Самоорганизация может быть выполнена с использованием аппарата сетей Кохонена [3, 5, 7]. Осуществление кластеризации-классификации структурирует библиотеку эталонных признаков путем внедрения механизма их коллективного взаимодействия, который реализуется как адаптивный процесс соревновательного обучения. За счет кластеризации совершается преобразование описаний эталонов из пространства «множество дескрипторов» к пространству «числовые вектора», что ускоряет распознавание [8]. Задачи построения оптимального классификатора и оптимальной системы признаков здесь считают тождественными [6]. Интеллектуальная обработка данных в системах голосования признаков, как правило, реализуется в виде набора эвристик [10].

Проведенные нами исследования говорят о том, что выигрыш в быстродействии распознавания в результате структурирования пространства признаков возрастает с увеличением параметров размера описаний, числа эталонов и уменьшением числа кластеров, и для конкретных приложений составляет несколько десятков раз [1, 3].

### 3 МАТЕРИАЛЫ И МЕТОДЫ

В рамках структурных подходов описания объектов рассматривают в виде множества дескрипторов – числовых векторов из  $R^n$ . Описание  $Z \subset R^n$  объекта представляют как мультимножество [1].

Пусть имеем базу  $\{Z^j\}_{j=1}^J$  описаний из  $J$  эталонов, а эталон, в свою очередь, есть множество  $Z^j = \{z_{jk}\}$ ,  $z_{jk} \in R^n$ ,  $Z^j \subset R^n$ ,  $j$  – номер эталона,  $k$  – номер ХП внутри описания эталона, параметр  $n$  фиксирован. Результатом самоорганизации есть кластерное представление базы  $\{Z^j\}_{j=1}^J$  [3, 4]. Если воспользоваться аппаратом сети Кохонена [7], объединяющим нелинейное проектирование и кластеризацию, то множество  $\{Z^j\}_{j=1}^J$  трансформируется к разбиению множеством кластеров  $\{Z^j\}_{j=1}^J \rightarrow C$ ,  $C = \cup_{i=1}^q C_i$ , причем  $C_i \cap C_a = \emptyset$ .

Распознавание на основе кластерных характеристик предполагает реализацию следующих шагов предварительной обработки:

- 1) формирование эталонного множества  $\{Z^j\}_{j=1}^J$ ;
- 2) кластеризация  $\{Z^j\}_{j=1}^J$  с получением множества центров  $\{c_1, c_2, \dots, c_q\}$ ,  $c_a \in R^n$  – центр кластера,  $q$  – число кластеров;  $m_i$  – объем  $i$ -го кластера;
- 3) вычисление множества  $T = [t_1, t_2, \dots, t_a, \dots, t_q]$  векторов-столбцов  $t_a = [t_a^1, t_a^2, \dots, t_a^J]$ , которые образуют матрицу  $T$  данных, характеризующую кластеры в аспекте числа элементов, отнесенных к эталону;
- 4) обработка матрицы  $T$  в целях отбора значимых данных.

Построим матрицу данных  $T$  для  $\{Z^j\}_{j=1}^J$ . Вычислим  $k_i(j) = \text{card}\{z \in C_i \mid z \in Z^j\}$  – число элементов эталона  $Z^j$ , отнесенных к  $C_i$ . Заполним значениями  $k_i(j)$  целочисленную матрицу данных  $T = \{t_i^j\}_{j=1, \dots, J}^{i=1, \dots, q}$ .

Обязательными этапами обработки матрицы  $T$ , на наш взгляд, есть:

- 1) устранение из анализа незначимых (по числу элементов) кластеров, в результате число столбцов сократится; на практике можно исключить кластеры с числом элементов 1–2% от общего объема;
- 2) нормирование строк матрицы путем деления на число элементов эталона

$$t_i^j = t_i^j / s_j. \tag{1}$$

При этом для исходной матрицы будет выполнено соотношение

$$m_i = \sum_{j=1}^J t_i^j, \tag{2}$$

а для нормированной –  $\sum_{i=1}^q t_i^j = 1$ .



Соотношение (1) соответствует распространенной в интеллектуальном анализе данных модели оценивания плотности распределения элементов  $j$ -го объекта, принадлежащих  $i$ -му кластеру [5, 8]. Нормированием (1) устраняем влияние размера эталона. Кроме соотношений (2), очевидно, в исходной матрице данных выполнено  $\sum_j s_j = \sum_i m_i$ , т.к. элементы  $\{Z^j\}_{j=1}^J$  принадлежат одному из кластеров, образующих нового разбиения.

Значения строк  $T$  отражают подобие множеств признаков в аспекте эталон-кластер, а после нормировки к 1 фактически характеризуют вероятности отнесения признака  $j$ -го эталона к одному из кластеров. Матрица  $T$  – это результат обучения с учителем, т.к. принадлежность признака эталону априорно задана в базе изображений.

Заметим, что важную роль играет степень равномерности распределения элементов эталона по построенной системе кластеров. Идеальной ситуацией есть принадлежность точек эталона одному из кластеров, что упрощает процесс статистического распознавания. Однако, наше моделирование показало, что в действительности такая ситуация встречается редко.

С другой стороны, столбец матрицы  $T$  характеризует весовое распределение точек кластера по системе эталонов. Здесь идеальным случаем также была бы принадлежность точек кластера одному из эталонов, что соответствует  $t_i^j \rightarrow 1$ . Нежелательным вариантом есть равномерное разделение точек кластера по множеству эталонов (равноценные элементы в столбце), что делает такой кластер бесполезным в распознавании. Напрашивается мысль о необходимости целенаправленной трансформации матрицы  $T$  для обеспечения качества распознавания. Немаловажным также представляется построение численного критерия, отражающего неравномерность значений элементов в строках/столбцах матрицы  $T$ .

Наряду с (1) представляет также интерес нормирование в столбце матрицы  $T$  вида:  $t_i^j = t_i^j / m_i$ , что исключило бы влияние размера кластера. При этом можно было бы говорить о распределении элементов кластера по эталонам. Однако это предполагает выравнивание объемов кластеров, что на практике обеспечить трудно, ибо результат кластеризации меняется в зависимости от параметров применяемого метода и состава базы изображений. Обеспечить же примерно равноценное число элементов в эталонах можно применением фильтрации, что делает более целесообразной нормировку (1).

Отметим, что при определении числа кластеров устанавливается компромисс между желаемой точностью аппроксимации данных в виде показателя качества (вероятность правильного распознавания) и быстродействия распознавания [7].

Результат самоорганизации – множество центров  $\{c_1, c_2, \dots, c_q\}$ ,  $c_i \in R^n$  составляют векторы из пространства  $R^n$ . Для признаков SURF [2] (вектор размерности 64) кластеризация приводит к сжатому представлению в виде матрицы  $C = \{\{c_{a,b}\}_{a=1}^q\}_{b=1}^{64}$ . Строки  $C$  образуют набор опорных точек пространства при распознавании (рис. 1).




Рисунок 1 – Схема предварительной обработки эталонных данных

Эффективным представляется проведение на этапе формирования эталонных характеристик интеллектуальной обработки  $L[T]$  матрицы  $T = \{t_i^j\}$  в целях акцентирования внимания на значимой для распознавания информации. Часто такая обработка имеет вид множества эвристик [10]. Признак-столбец  $t^j$  с равными значениями компонентов сигнализирует, что кластер  $c_j$  «не различает» эталоны. Наиболее подходящая ситуация – когда один из компонентов  $t^j$  стремится к 1 или значительно превышает значение 0,5. Именно здесь допустима бинарная обработка. Можно также обработать вектор  $t^j$ , чтобы выделить 1–3 значимые компоненты. Варианты обработки могут быть:

- нормирование матрицы  $T$ , исключая влияние размера эталонного описания (строка) и/или объема кластеров (столбец);
- изъятие из кластерного представления состава малочисленных кластеров, например, общая доля которых составляет менее 10% объема описания базы; при этом число столбцов матрицы  $T$  сократится, что способствует упрощению обработки;
- анализ содержания столбцов матрицы  $T$ : построение укороченного вариационного ряда из 1–3 элементов; обнуление малых по значению элементов (например, меньших 0,05), если только они не составляют весь столбец; бинарная обработка путем выделения максимума, превышающего значение 0,5, и т.п.;
- в случае равноценных элементов в столбце целесообразно исключить лишь незначимые элементы.

Важно, чтобы вследствие обработки  $L[T]$  у эталонов осталось представительство ненулевых элементов в кластерах. В противном случае распознавание станет проблематичным. Традиционными подходами к нормированию положительных данных есть деление на их сумму или на максимум [5].

На этапах построения матрицы данных и в процессе распознавания применимы следующие модели обработки  $T$ :

- 1) «бинарная» – выбирается единственный весомый кластер или наиболее подходящий из эталонов;
- 2) «расширенное множество альтернатив» – формируется подмножество значимых кластеров и/или эталонов;
- 3) «полная матрица данных» – используются характеристики кластеров и эталонов в полном объеме;
- 4) комбинирование – применяются модели 1–3 в сочетаниях.

Бинарный путь отнесения признака к классу – простая модель, в то время как причисление к нескольким кластерам или классам с разными весами соответствует мягкой классификации (нечеткое представление). Учитывая, что при распознавании изображений из-за влияния фона, помех и других объектов наблюдается значительное число ложных ХП, в условиях высокого уровня искажений отдаются предпочтение первому способу [1]. В то же время в задачах, где эталоны имеют существенное пересечение в пространстве признаков, лучшей восприимчивостью к различиям объектов обладает способ мягкой классификации.

Предлагаемая здесь аппроксимация пространства признаков путем кластерного представления вносит коррекцию в применение моделей распознавания. Может оказаться, что при незначительном числе кластеров отдельные классы при упрощенной бинарной обработке естественным образом станут неразличимы. Возможным выходом есть: использование полного объема данных, увеличение числа кластеров и др.

Известны две основные модели структурного распознавания [1]:

1) раздельный анализ ХП объекта и отнесение их к эталону; победителем считается класс, набравший наибольшее число голосов;

2) построение интегрального векторного описания объекта и выбор эталона с наивысшим подобием путем сопоставления со списком эталонов.

Первая модель устойчива к локальным помехам. Второй способ применяют в ситуациях преобладающего влияния флуктуационных помех, он эффективнее в вычислительном плане. Примером векторного представления для второй модели есть описание в виде  $q$ -вектора из количеств кластерных элементов.

Фактически здесь нами предложен новый способ структурного распознавания, где эталонные описания подаются в кластерном виде, а классификация базируется на предварительном отнесении к кластерам или на оптимизации подобия векторных описаний.

Распознавание объекта по описанию  $Z$  приобретает вид двухэтапного отображения

$$R = R_2(R_1[Z]), R: Z \rightarrow J. \quad (3)$$

На первом этапе  $R_1: Z \rightarrow C$  признаки  $Z$  относят к одному/нескольким кластерам, а затем отображение  $R_2: C \rightarrow J$  агрегировано по множеству  $Z$  оптимально определяет класс объекта из списка эталонов. На обоих этапах принятия решений (3) вычисляем и применяем характеристики отдельных ХП, а также значения параметров кластеров. Реализацию (3) осуществим оптимизацией меры подобия по результатам анализа всех признаков объекта.

Этот путь намного эффективнее в плане объема вычислений, чем сопоставление типа множество-множество. Навигация по кластерам является результативной альтернативой поиска по объемному множеству эталонных признаков.

Модель определения номера  $v$  оптимального кластера для  $z \in Z$ :

$$v = \arg \min_{a=1,q} \{\rho(c_a, z)\}_{a=1}^q. \quad (4)$$

Выбор класса элемента после оптимизации (4)  $\forall z \in Z$  можно осуществить как

$$b = \arg \max_j \{t_v^j\}_{j=1}^J. \quad (5)$$

В итоге бинарной обработки (5)  $\forall z \in Z$  получим номер  $b$  класса, а для всего объекта – вектор классов  $h = \{h_j\}_{j=1}^J$ , где  $h_j$  – число элементов  $Z$ , назначенных в соответствии с моделью (5) в класс с номером  $j$ . При этом теоретически выполнено  $\sum_{j=1}^J h_j = s$ , где

$s = \text{card}(Z)$ . В приложениях это условие часто нарушается, т.к. признаки в ходе обработки частично могут быть потеряны, а также могут появиться ложные признаки.

Подмножество кластеров/классов будем формировать путем редукции

$$V_u = \{v \in M \mid \text{Ind}[\{A\}, u]\}, \quad (6)$$

В результате обработки (6) для  $z \in Z$  получим  $u$  значений  $a_1, a_2, \dots, a_u$ , агрегацией которых реализуется  $R_2$ .

Примером (6) есть правило «три наибольших» – при построении (4) определяем три наиболее подходящих кластера по расстоянию, или в столбце  $T$  формируем тройку классов с наибольшими значениями. В результате редукции анализируется некоторая подматрица  $T$ , и как результат – для элемента  $z \in Z$  формируется вектор  $t^*[z] = \{t^1, \dots, t^J\}$  значений функции принадлежности к эталонам. Накоплением векторов  $t^*$  на объекте из  $s$  элементов получим  $J$ -компонентный вектор классов  $h$ :

$$h = \sum_{i=1}^s t^*[z]. \quad (7)$$

В выражении (5) анализируем целое значение, а в (7) – вещественное. Класс объекта определим как

$$k = \arg \max_j \{h_j\}_{j=1}^J. \quad (8)$$

Метод распознавания на основе кластерного представления изобразим последовательностью этапов (схема приведена на рис. 2).

1. Построение описания  $Z$  для распознаваемого изображения.

2.  $\forall z \in Z$  определяем в соответствии с (4) номер кластера или в виде (6) формируем подмножество  $V_u$ .

3. По номеру кластера приписываем  $Z$  номер класса в соответствии с (5) или вектор характеристик  $t^*[z]$ .

4. В зависимости от модели обработки: определяем класс элемента согласно (6), либо агрегируем вектор  $t^*$  в соответствии с (7).

5. Повторяем шаги 2–4  $\forall z \in Z$ .

6. Согласно модели (8) устанавливаем класс объекта  $Z$ .

В обсуждаемом методе вместо традиционной оптимизации подобия ХП на множестве эталонов осуществляется значительно менее масштабная в вычислительном плане оптимизация на множестве кластеров, опре-

деляется значение параметров кластера и агрегировано формируется вектор характеристик классов объекта. Разработанные процедуры однозначно устанавливают процесс распознавания на основе анализа вектора  $h$ , содержащего степени принадлежности к классам.

Универсальным прикладным критерием  $\eta$  при оценивании эффективности метода распознавания есть отношение ближайшего локального максимума подобия к глобальному максимуму [9]

$$\eta = \mu_{\max 2} / \mu_{\max 1} = \max_{j=1, \dots, J} \mu(Z, Z^j). \quad (9)$$

Чем меньше  $\eta$ , тем увереннее распознается объект. При этом (9) априори предполагает правильное определение класса объекта.

Соотношение (7) есть пример меры  $\mu$  в (9). Примером  $\mu$  может быть также нормированный коэффициент корреляции  $\gamma$

$$\gamma(Z, Z^j) = \sum_{i=1}^q (t_i[Z]t_i[Z^j]) / (\sqrt{\sum_{i=1}^q (t_i[Z])^2} \sqrt{\sum_{i=1}^q (t_i[Z^j])^2}). \quad (10)$$

Отметим также, что процедурные меры взвешенного голосования вида (7) есть мерами подобия и являются несимметричными по своей природе, в то время как (10) обладает симметрией относительно своих аргументов.

#### 4 ЭКСПЕРИМЕНТЫ

Продемонстрируем работу и выявим особенности предложенного метода путем программного моделирования на примере. Вычисление множества ХП методом SURF осуществлено для базы из 25 изображений гербов городов Украины. На рис. 3, а-г приведены примеры изображений. Проведена кластеризация множества дескрипторов методом сети Кохонена [3]. Рис. 4 включает изображение одного из центров кластеров. Табл. 1 содержит матрицу данных в разрезе «эталон-кластер» после кластеризации 5-ти эталонов базы и распределения признаков по 8-ми кластерам.

Вначале исключим малочисленные кластеры 5, 7, содержащие менее 2% объема данных. В результате обязательной нормировки в строке получим табл. 2 (матрица данных). Моделирование показало, что в данной си-

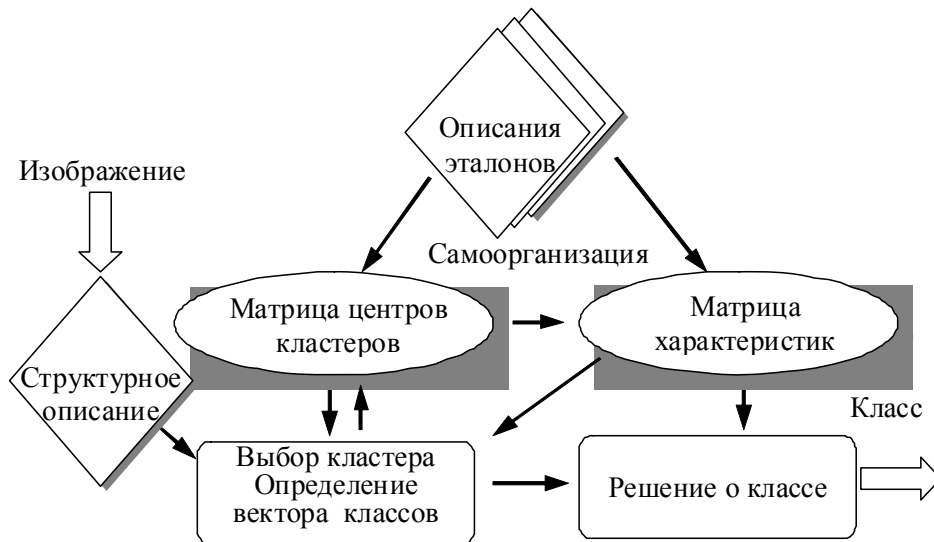


Рисунок 2 – Распознавание на основе кластеров-классов ХП



Рисунок 3 – Изображения из базы гербов городов Украины:  
 а – Днепр, б – Львов, в – Киев, г – Харьков

туации простая бинарная обработка в строке и столбце не приводит к успеху, т.к., например, все 253 точки герба Днепра будут отнесены к другим классам в силу того, что ни по одному кластеру у герба Днепра максимума в столбце нет. Не совсем приемлемым оказался и вариант с тремя максимальными элементами в столбце.

Возможным выходом может быть увеличение числа кластеров или классов. Зато при вычислении подобия (10) достигается верное распознавание.

Использование полной матрицы данных также обеспечивает уверенное правильное распознавание для обои вариантов нормирования: на сумму и на максимум в столбце матрицы. Табл. 3 содержит значения подобия классов (7) при нормировании на максимум в столбце. На главной диагонали стоят максимальные элементы в строке, что соответствует факту правильного распознавания. Степень уверенности оценивается критерием (9).




Рисунок 4 – Пример центра кластера

Таблица 1 – Количества ХП в кластерном представлении эталонов

Изображения гербов	Номер кластера							
	1	2	3	4	5	6	7	8
Днепр	29	24	111	5	61	23	29	24
Львов	83	26	83	24	43	70	83	26
Киев	40	46	82	31	74	31	40	46
Харьков	58	19	188	29	7	41	58	19
Кременчуг	29	26	159	54	39	8	29	26
База	239	141	623	143	224	173	141	623

Таблица 2 – Нормированная матрица данных

Изображения гербов	Номер кластера							
	1	2	3	4	6	8		
Днепр	0,115	0,095	0,439	0,020	0,241	0,091		
Львов	0,252	0,079	0,252	0,073	0,131	0,213		
Киев	0,132	0,151	0,270	0,102	0,243	0,102		
Харьков	0,170	0,056	0,550	0,085	0,020	0,120		
Кременчуг	0,092	0,083	0,505	0,171	0,124	0,025		

Таблица 3 – Пример матрицы подобия классов

	1	2	3	4	5
1	187,637	150,356	168,589	159,868	164,37
2	195,522	237,971	200,842	203,269	173,911
3	202,574	185,58	214,396	164,801	187,322
4	216,106	211,301	185,401	271,999	241,612
5	204,65	167,468	194,101	222,538	245,556

Значения критерия (9) для трех видов обработки в варианте «полная матрица данных»: нормирование на сумму, нормирование на максимум в столбце, вычисление коэффициента корреляции (10) составили: 0,88, 0,90, 0,93. Как видим, обсуждаемые меры подобия здесь имеют преимущество перед коэффициентом (10), т.к. они меньше по величине.

Моделирование для 15-ти кластеров при тех же исходных данных обнаружило, что значения критерия (9) равны: 0,89, 0,91, 0,93, что практически равноценно значениям для 8 кластеров. Отметим, что при этом объеме кластеров уменьшается, элементы матрицы данных становятся менее весомыми. Несмотря на то, что степень уверенности для решений (отношение числа голосов к объему описания) увеличилась, бинарная обработка и «три максимальных элемента в столбце» здесь также не обеспечивают распознавание. Учитывая, что с увеличением числа кластеров время обработки возрастает, можно рекомендовать на предварительном этапе одноразово определиться с минимальным числом кластеров, которые обеспечивают адекватное распознавание. Не стоит забывать также, что результат распознавания, основанный на интеллектуальном анализе, целиком зависит от данных базы изображений. Для других данных он может оказаться иным.

### 5 РЕЗУЛЬТАТЫ

Основным результатом исследования есть построение метода структурного распознавания, где эталонные описания подаются в кластерном виде, а распознавание базируется на классификации структурных признаков объекта в пространстве кластеров с дальнейшим вычислением и оптимизацией подобия векторных описаний. Проведенные эксперименты для различных вариантов обработки подтверждают работоспособность метода. Навигация по кластерам является действенной альтернативой поиска по объемному множеству эталонных признаков базы. Ее применение ускоряет процесс распознавания в десятки раз.

### 6 ОБСУЖДЕНИЕ

Отсутствие перспективы улучшения характеристик с увеличением числа кластеров для рассмотренного примера можно объяснить тем, что данные этой базы изображений достаточно хорошо сгруппированы, и кластеризация, проведенная в целях повышения быстродействия, увеличивает значение ошибки квантования [3]. Наше моделирование показало, что ошибка квантования в рамках единого кластера для этого примера ниже, чем для 8 или 15 кластеров. Другие исходные данные могут дать обратный эффект.

Инвариантность распознавания к геометрическим преобразованиям визуальных объектов обеспечивается на этапе построения дескрипторов характерных признаков.

В условиях локальных искажений предпочтение имеет модель принятия решения о классе отдельно для каждого ХП. В случае существенного пересечения классов в пространстве признаков, где нужна повышенная восприимчивость к различиям объектов, применим способ мягкой классификации отнесения ХП синхронно к подмножеству классов.

Некоторые упрощения обработки, связанные, например, с бинаризацией решений о классе характерных признаков объекта, могут оказаться неэффективными в силу высокой степени подобия для подмножеств структурных признаков эталонов.

## ВЫВОДЫ

В результате кластеризации описание объектов приведено к принятой в интеллектуальной обработке данных системе координат объект-признаки, где значениями признаков выступают характеристики кластерного представления. За счет введенной интеллектуальной обработки описаний эталонов и распознаваемого объекта происходит усиление чувствительности метода распознавания к различиям в имеющихся данных.

Научная новизна исследования состоит в построении метода структурного распознавания на основе применения интеллектуального анализа данных путем построения кластерного сжатого представления признакового пространства, а также вычисления и использования его характеристик. Получено векторное описание пространства признаков, за счет чего существенно повышается быстродействие распознавания.

Практическая ценность работы – получение экспериментальных оценок и результатов анализа качества распознавания на основе кластеризации признаков для примеров прикладных баз изображений.

Перспективой исследования может быть проведение анализа значений параметров эталонных структурных признаков в целях построения новых значимых агрегированных характеристик. Целесообразно также исследовать вопрос о выборе оптимального параметра числа кластеров для обеспечения качественной аппроксимации данных в целях распознавания.

## СПИСОК ЛИТЕРАТУРЫ

1. Гороховатский В. А. Структурный анализ и интеллектуальная обработка данных в компьютерном зрении : монография / В. А. Гороховатский. – Х. : Компания СМИТ, 2014. – 316 с.
2. Bay H. Surf: Speeded up robust features / H. Bay, T. Tuytelaars, L. Van Gool // Computer Vision: Ninth European Conference on Computer Vision, Graz, 7–13 May, 2006: proceedings. – Berlin : Springer, 2006. – P. 404–417.
3. Берестовский А. Е. Нейросетевые технологии самообучения в системах структурного распознавания визуальных объектов / А. Е. Берестовский, А. Н. Власенко, В. А. Гороховатский // Реєстрація, зберігання і обробка даних. – 2015. – Т. 17, № 1. – С. 108–120.
4. Гороховатский В. А. Построение и применение функции принадлежности для результативного структурного анализа изображений / В. А. Гороховатский, Ю. А. Куликов, А. Е. Берестовский // Бионика интеллекта. – 2015. – №1 (84). – С. 13–18.
5. Паклин Н.Б. Бизнес-аналитика: от данных к знаниям : учеб. пособ. / Н. Б. Паклин, В. И. Орешков. – СПб. : Питер, 2013. – 704 с.
6. Duda R. O. Pattern classification / R. O. Duda, P. E. Hart, D. G. Stork. – 2ed., Wiley, 2000. – 738 p.
7. Кохонен Т. Самоорганизующиеся карты / Т. Кохонен ; пер. 3-го англ. изд. – М. : БИНОМ, Лаборатория знаний, 2013. – 655 с.
8. Маннинг К. Д. Введение в информационный поиск / К. Д. Маннинг, П. Рагхаван, Х. Шютце ; пер. с англ. – М. : ООО И. Д. Вильямс, 2011. – 528 с.
9. Quality Criteria for Multidimensional Object Recognition Based Upon Distance Matrices / A. V. Gorokhovatsky, V. A. Gorokhovatsky, A. N. Vlasenko, N. V. Vlasenko // Telecommunications and Radio Engineering. – 2014. – Vol. 73, No. 18. – P. 1661–1670.
10. Мулеса О. Ю. Методи врахування суб'єктивного характеру вхідних даних для задачі голосування / О. Ю. Мулеса // Східноєвропейський журнал передових технологій. Серія: процеси управління. – 2015. – Том 1, № 3 (73). – С. 20–25.

Статья поступила в редакцию 10.02.2016.

После доработки 05.03.2016.

Гороховатський В. О.<sup>1</sup>, Гороховатський О. В.<sup>2</sup>, Берестовський А. Е.<sup>3</sup>

<sup>1</sup>Д-р техн. наук, професор, професор кафедри інформаційних технологій, Харківський навчально-науковий інститут ДВНЗ «Університет банківської справи», Харків, Україна

<sup>2</sup>Канд. техн. наук, доцент, доцент кафедри інформатики та комп'ютерної техніки, Харківський національний економічний університет імені Семена Кузнеця, Харків, Україна

<sup>3</sup>Аспірант кафедри інформатики, Харківський національний університет радіоелектроніки, Харків, Україна

## СТРУКТУРНЕ РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ З ВИКОРИСТАННЯМ МОДЕЛЕЙ ІНТЕЛЕКТУАЛЬНОЇ ОБРОБКИ І САМООРГАНІЗАЦІЇ ОЗНАК

Статтю присвячено дослідженню проблеми розпізнавання зображень у комп'ютерному зорі на основі множини структурних SURF-ознак. У просторі структурних ознак виконано самоорганізацію з метою збільшення швидкодії процесу розпізнавання. В якості апарату для самоорганізації використано нейронну мережу Кохонена.

Об'єктом дослідження є метод обчислення подібності описів і моделі інтелектуальної обробки у новому просторі ознак. Предметом дослідження є систематизація і групування множин структурних ознак візуальних об'єктів.

Метою роботи є побудова методу структурного розпізнавання із застосуванням вхідних даних у вигляді множини кластерів структурних ознак, отриманих в результаті самоорганізації. Завданнями дослідження є вивчення особливостей і аналіз моделей для обчислення характеристик кластерів, побудова модифікованих заходів структурної подібності, експериментальне оцінювання якості розпізнавання для різних способів зіставлення описів у прикладній базі візуальних зразків.

Запропоновано побудову методу розпізнавання зображень на основі еталонних описів у кластерному виді, а розпізнавання базується на класифікації структурних ознак об'єкта в просторі кластерів з подальшим обчисленням і оптимізацією подібності векторних описів.

Проведено моделювання та експериментальні дослідження запропонованого методу розпізнавання на тестовій множині зображень із застосуванням характерних ознак SURF. Підтверджено працездатність і ефективність методу в плані швидкодії, отримані оцінки якості розпізнавання для різноманітних варіантів оброблення.

**Ключові слова:** комп'ютерний зір, структурне розпізнавання зображень, характерні ознаки, дескриптори, структурний опис, метод SURF, самоорганізація, кластеризація, мережа Кохонена, подібність векторних описів, матриця характеристик кластерів.

Gorokhovatsky V. A.<sup>1</sup>, Gorokhovatskyi A.V.<sup>2</sup>, Berestovskiy A. E.<sup>3</sup>

<sup>1</sup>Dr.Sc., Professor, Professor of the Information Technologies Department, Kharkiv Educational and Scientific Institute SHEI “The University of banking”, Kharkiv, Ukraine

<sup>2</sup>Ph.D., Associate Professor, Associate Professor of Informatics and Computer Technologies Department, Simon Kuznets Kharkiv National University of Economics, Kharkiv, Ukraine

<sup>3</sup>Post-graduate student of the Informatics Department, Kharkiv National University of Radioelectronics, Kharkiv, Ukraine

### STRUCTURAL IDENTIFICATION OF IMAGE RECOGNITION BASED WITH MODELS OF INTELLECTUAL SELF-ORGANIZATION FEATURES

Paper describes an investigation about the problem of image recognition in computer vision based on a set of structural SURF-features. Self-organization process is proposed to be performed in space of structural features with a goal to increase recognition process performance. Kohonen neural network is used as self-organization method.

The object of research is the method of similarity calculations and models of intelligent data processing in the new feature space. The subject of research is the systematization and grouping of sets of structural features of visual objects.

Goal of a paper is to construct structural recognition method based on input data as a set of cluster structural features obtained as a result of self-organization. The objectives of the research are the investigation of the features and analysis of models to calculate clusters of features, the construction of the modified measures of structural similarity, the experimental evaluation of the recognition quality for different ways of descriptions comparison in the application-based visual image database.

Construction of an image recognition method based on etalon descriptions as a cluster was proposed, recognition is based on the classification of the structural features of an object in cluster space with further calculation and optimization of the similarity vector descriptions.

Experimental investigations and simulations of the proposed recognition method on the test image set with the use of SURF characteristic features were performed. Performance boost and efficiency of the method were confirmed, estimation of recognition quality for different processing options was performed.

**Keywords:** computer vision, structural image recognition, features, descriptors, structural description, SURF, self-organization, clustering, Kohonen network, descriptions similarity vector, matrix of cluster characteristics.

### REFERENCES

1. Gorokhovatsky V. Strukturny'j analiz i intelektual'naya obrabotka danny'x v komp'yuternom zrenii: monografiya. Kharkiv, Kompaniya SMIT, 2014, 316 p.
2. Bay H., Tuytelaars T., Van Gool L. Surf: Speeded up robust features, *Computer Vision: Ninth European Conference on Computer Vision, Graz, 7–13 May, 2006: proceedings*. Berlin, Springer, 2006, pp. 404–417. DOI: 10.1007/11744023.
3. Berestovskiy A., Vlasenko A. N., Gorokhovatsky V. A. Nejrosetevy'e tehnologii samoobucheniya v sistemax strukturnogo raspoznavaniya vizual'ny'x ob'ektov, *Reestraciya, zberigannya i obrobka danix*, 2015, Vol. 17, No. 1, pp. 108–120.
4. Gorokhovatsky V. A., Kulikov Yu. A., Berestovskiy A. E. Postroenie i primenenie funkcii prinallezhnosti dlya rezul'tativnogo strukturnogo analiza izobrazhenij, *Bionika intelekta*, 2015, No. 1 (84), pp. 13–18.
5. Paklin N. B., Oreshkov V. I. Biznes-analitika: ot danny'x k znaniyam: uch posob. Sankt-Peterburg, Piter, 2013, 704 p.
6. Duda R. O., Hart P. E., Stork D. G. Pattern classification. Second edition. New-York, Wiley-Interscience, 2000, 738 p.
7. Koxonen T. per. 3-go angl. izd. Samoorganizuyushhiesya karty'. Moscow, BINOM, Laboratoriya znaniy, 2013, 655 p.
8. Manning K. D., Ragxavan P., Shyutce X. ; per. s angl. Vvedenie v informacionnyj poisk Moscow OOO I. D. Vil'yams, 2011, 528 p.
9. Gorokhovatskyi A. V., Gorokhovatsky V. A., Vlasenko A. N., Vlasenko N. V. Quality Criteria for Multidimensional Object Recognition Based Upon Distance Matrices, *Telecommunications and Radio Engineering*, 2014, Vol. 73, No. 18, pp. 1661–1670.
10. Mulesa O. Yu. Metodi vraxuvannya sub'ektivnogo xarakteru vxidnix danix dlya zadachi golosuvannya, *Sxidno-evropejs'kij zhurnal peredovix tehnologij. Seriya: procesi upravlinnya*, 2015, Vol. 1, No. 3 (73), pp. 20–25.

## ПОСТРОЕНИЕ ПОЛНОСТЬЮ ОПРЕДЕЛЕННЫХ НЕЙРО-НЕЧЕТКИХ СЕТЕЙ С РЕГУЛЯРНЫМ РАЗБИЕНИЕМ ПРОСТРАНСТВА ПРИЗНАКОВ НА ОСНОВЕ ВЫБОРОК БОЛЬШОГО ОБЪЕМА

Решена проблема автоматизации синтеза моделей для классификации образов по признакам. Предложен метод синтеза нейро-нечетких моделей по прецедентам, способный получать полностью определенные нейромодели на основе регулярного разбиения признаков. Метод рассчитывает координаты центров кластеров как координаты центров прямоугольных блоков в пространстве интервалов признаков, а принадлежности кластеров к классам определяет по обучающей выборке: для кластеров, покрытых наблюдениями, принадлежность определяется по максимуму частоты экземпляров соответствующих классов в кластере, а для кластеров, не покрытых наблюдениями, принадлежность определяется по максимальному потенциалу, наводимому на данный кластер кластерами с известной принадлежностью к классам. Полученный набор кластеров-правил отображается в структуру нейро-нечеткой сети Мамдани, а ее параметры настраиваются на основе параметров разбиения признаков и центров кластеров. Предложенный метод не требует загрузки всей обучающей выборки в память ЭВМ и существенно ускоряет процесс синтеза моделей, обеспечивая при этом приемлемый уровень обобщения данных получаемой нейромоделью. Разработано программное обеспечение, реализующее предложенный метод, а также проведены эксперименты, подтвердившие работоспособность разработанного математического обеспечения и позволяющие рекомендовать его для построения нейро-нечетких моделей на основе выборок большого объема.

**Ключевые слова:** нейро-нечеткая сеть, обучение, синтез, классификация.

### НОМЕНКЛАТУРА

ЭВМ – электронная вычислительная машина;  
 $a_{i,p}, b_{i,p}, c_{i,p}, d_{i,l}$  – параметры функции принадлежности к  $l$ -му терму  $i$ -го признака;  
 $E$  – ошибка сети для задач с дискретным выходом;  
 $f$  – критерий качества модели;  
 $F()$  – структура нейромодели;  
 $i, j$  – номера признаков;  
 $k$  – номер класса;  
 $K$  – число классов;  
 $l$  – номер интервала;  
 $l_j$  – номер интервала  $j$ -го признака;  
 $L$  – число интервалов, на которые разбивается признак;  
 $N$  – число входных признаков;  
 $N_w$  – общее число весов нейромодели;  
 $opt$  – условное обозначение оптимума;  
 $q$  – номер блока-кластера;  
 $Q$  – число кластеров;  
 $R(Y_q, Y_p)$  – расстояние между  $q$ -м и  $p$ -м кластерами;  
 $S$  – объем выборки;  
 $s$  – номер экземпляра выборки;  
 $S_q$  – число экземпляров, попавших в  $q$ -й кластер;  
 $S^k$  – число экземпляров в выборке, принадлежащих к  $k$ -му классу;  
 $S_q^k$  – число экземпляров  $k$ -го класса, попавших в  $q$ -й кластер;  
 $w$  – параметры нейромодели;  
 $x$  – набор входных векторов прецедентов;  
 $X$  – набор прецедентов;  
 $x_j$  –  $j$ -й входной признак;  
 $x^s$  – набор входных признаков  $s$ -го прецедента;  
 $x_j^s$  – значение  $j$ -го входного  $s$ -го прецедента;

$x_j^{\min}, x_j^{\max}$  – минимальное и максимальное значения признака  $x_j$ ;  
 $y$  – выходной признак;  
 $Y_q$  – номер класса, сопоставленный  $q$ -му кластеру;  
 $y^s$  – значение выходного признака для  $s$ -го прецедента;  
 $\delta_j$  – длина интервала, на которые разбивается диапазон значений  $j$ -го признака;  
 $\lambda_{q,j}$  – номер интервала  $j$ -го признака, соответствующий  $q$ -му блоку-кластеру;  
 $\varepsilon$  – приемлемый уровень ошибки;  
 $\mu_k$  – принадлежность к  $k$ -му классу;  
 $\mu^q$  – принадлежность к  $q$ -му эталону;  
 $\mu_{i,l}(x^s)$  – функции принадлежности к  $l$ -му терму  $i$ -го признака.

### ВВЕДЕНИЕ

Нейро-нечеткие сети [1–4] являются парадигмой вычислительного интеллекта, широко используемой при решении задач автоматизации принятия решений в техническом и биомедицинском диагностировании, неразрушающем контроле качества и управлении. Это объясняется способностью нейро-нечетких сетей к обучению по прецедентам, интерпретируемостью получаемых нейромоделей, возможностью интегрировать имеющиеся экспертные знания в нейромодель, массивным параллелизмом вычислений нейро-нечетких моделей, возможностью использования для синтеза и обучения нейро-нечетких сетей методов оптимизации и машинного обучения.

Объект исследования – процесс построения нейро-нечетких моделей.

Большинство известных методов синтеза нейро-нечетких сетей [1–4] требуют загрузки всей обучающей

выборки в память ЭВМ, являются медленными, приводят к получению моделей, недостаточно хорошо проявляющих обобщающие и аппроксимационные свойства, что ограничивает применение нейро-нечетких моделей на практике. Для выборок данных большого объема применение известных методов построения нейро-нечетких моделей оказывается крайне затруднительным.

Предмет исследования – методы построения нейро-нечетких моделей на основе больших выборок данных.

Целью работы являлось создание метода синтеза нейро-нечетких моделей по прецедентам, способного получать полностью определенные нейромодели, не требующего загрузки всей обучающей выборки в память ЭВМ и существенно ускоряющего процесс синтеза моделей по сравнению с известными методами, обеспечивающего при этом приемлемый уровень обобщения данных получаемой нейромоделью.

### 1 ПОСТАНОВКА ЗАДАЧИ

Пусть мы имеем исходную выборку  $X = \langle x, y \rangle$  – набор  $S$  прецедентов о зависимости  $y(x)$ ,  $x = \{x^s\}$ ,  $y = \{y^s\}$ ,  $s = 1, 2, \dots, S$ , характеризующихся набором  $N$  входных признаков  $\{x_j\}$ ,  $j = 1, 2, \dots, N$ , и выходным признаком  $y$ . Каждый  $s$ -й прецедент представим как  $\langle x^s, y^s \rangle$ ,  $x^s = \{x_j^s\}$ ,  $y^s \in \{1, 2, \dots, K\}$ ,  $K > 1$ .

Тогда задача синтеза нейро-нечеткой модели зависимости  $y(x)$  будет заключаться в определении такой структуры  $F()$  и значений параметров  $w$  модели, при которых будет удовлетворен критерий качества модели  $f(F(), w, \langle x, y \rangle) \rightarrow opt$  [5].

Для задач с дискретным выходом критерий качества модели  $f$  определяют на основе ошибки обученной сети:

$$E = \frac{1}{S} \sum_{s=1}^S |y^s - F(w, x^s)| \rightarrow \min.$$

### 2 ЛИТЕРАТУРНЫЙ ОБЗОР

Наиболее простым с точки зрения реализации способом синтеза нейро-нечетких моделей является разбиение пространства признаков и выделение правил человеком [3]. Однако это возможно лишь в очень хорошо изученных областях и сопряжено с субъективным подходом эксперта.

Другим, относительно простым, способом синтеза нейро-нечетких моделей является разбиение пространства признаков человеком и формирование правил по набору прецедентов путем преобразования каждого прецедента в отдельное правило [4]. Однако это сопряжено с субъективным подходом к формированию разбиения и может приводить к построению недостаточно точных или плохо обобщающих данные моделей.

Синтез структуры нейро-нечетких сетей, как правило, осуществляют путем разбиения пространства признаков на кластеры и формирования для каждого кластера правила отнесения экземпляров к кластеру, которые отображаются затем в структуру нейро-нечеткой сети [6]. При этом проблемами являются выбор способа разбиения значений признаков на интервалы и выбор метода кластер-анализа, а также необходимость вовлечения человека в процесс выбора данных методов и задания разбиения, а также определения экспертных правил.

Сети, построенные на основе разбиения и правил, полностью покрывающих признаковое пространство, ограниченное интервалами значений признаков, будем называть полностью определенными.

Сети, построенные на основе разбиения и правил, покрывающих лишь частично признаковое пространство, ограниченное интервалами значений признаков, будем называть частично определенными.

В случае синтеза нейро-нечетких моделей по прецедентам для выборок данных ограниченного объема это дополнительно приводит к ряду проблем:

- если выборка покрывает не все пространство признаков и / или это покрытие является существенно неравномерным, то выделенные кластеры и правила, а также синтезированная на их основе частично определенная сеть могут недостаточно хорошо аппроксимировать (интерполировать и экстраполировать) моделируемую зависимость и плохо обобщать данные;

- процесс синтеза структуры сети не учитывает такие свойства результирующей модели как точность обобщения, сложность, интерпретируемость, что приводит к получению неоптимальных по данным свойствам моделей.

В случае синтеза нейро-нечетких моделей по прецедентам для выборок данных большого объема и значительной размерности признакового пространства из-за невозможности загрузки всей выборки в память ЭВМ процесс построения нейро-нечеткой модели становится крайне затруднительным и является неприемлемым из-за значительных затрат времени на выполнение синтеза и обучения нейромодели.

Поэтому необходимо создать метод синтеза полностью определенных нейро-нечетких моделей, не требующий загрузки всей обучающей выборки в память ЭВМ, ускоряющий процесс синтез моделей и обеспечивающий приемлемый уровень обобщения данных.

### 3 МАТЕРИАЛЫ И МЕТОДЫ

Для обеспечения скорости разбиения признакового пространства и его независимости от человека предлагается использовать регулярное разбиение диапазонов значений признаков на интервалы. Число интервалов для разбиения диапазонов значений признаков целесообразно выбирать таким образом, чтобы обеспечить обобщение данных.

Для существенного сокращения затрат на процесс синтеза структуры нейро-нечеткой модели предлагается определять координаты центров кластеров как координаты центров прямоугольных блоков в пространстве признаков без учета выборки данных, но принадлежности кластеров к классам определять по выборке. Это позволит заранее рассчитать параметры интервалов признаков, а также координаты центров кластеров без фактического выполнения кластер-анализа, но для определения правил отнесения экземпляров к классам на основе центров кластеров потребует всего одного просмотра выборки, оперируя в памяти всего одним экземпляром.

Для построения полностью определенных сетей на основе выборки, не полностью покрывающей признаковое пространство, предлагается принадлежность кластеров к классам.



Для кластеров, покритих наблюдениями, определять по максимуму частоты экземпляров соответствующих классов в кластере, а для кластеров, не покритых наблюдениями, принадлежность определять по максимальному потенциалу [7, 8], наводимому на данный кластер кластерами с известной принадлежностью к классам.

Полученный набор правил может быть легко отображен в структуру сети Мамдани, а ее параметры настроены на основе параметров разбиения признаков и центров кластеров.

Формально предложенный метод можно изложить следующим образом.

Этап 1. Инициализация. Задать обучающую выборку  $\langle x, y \rangle$ . Определить  $N, S, K, \{S^k\}, k = 1, 2, \dots, K; \{x_j^{\min}\}, \{x_j^{\max}\}, j = 1, 2, \dots, N$ . Задать число интервалов, на которые разбиваются диапазоны значений признаков  $L, L \geq 2$ . Задать приемлемый уровень ошибки  $\varepsilon$ .

Этап 2. Формирование разбиения пространства признаков. Определить число кластеров  $Q=L^N$ . Для  $q=1, 2, \dots, Q, j=1, 2, \dots, N, l=1, 2, \dots, L$  установить  $\lambda_{q,j}=l$ . Установить  $S_q^k=0, q=1, 2, \dots, Q, k=1, 2, \dots, K$ .

Определить длину интервала каждого  $j$ -го признака:

$$\delta_j = \frac{x_j^{\max} - x_j^{\min}}{L}, j = 1, 2, \dots, N.$$

Этап 3. Определение числа экземпляров классов в кластерах.

Последовательно для экземпляров обучающей выборки ( $s=1, 2, \dots, S$ ):

– считать из выборки очередной  $s$ -й экземпляр и загрузить в память ЭВМ;

– определить номера интервалов признаков, в которые попал экземпляр  $x^s$ :

$$l_j = \left\lfloor 1 + \frac{x_j^s - x_j^{\min}}{\delta_j} \right\rfloor, j = 1, 2, \dots, N;$$

– определить номер блока-кластера  $q$ , в который попал экземпляр  $x^s$ :  $q=1, 2, \dots, Q; \lambda_{q,j}=l_j, j=1, 2, \dots, N$ .

– принять  $S_q^{y^s} = S_q^{y^s} + 1, S_q = S_q + 1$ .

Этап 4. Определение принадлежности кластеров к классам.

Для  $q$ -го кластера,  $q=1, 2, \dots, Q$ , принять:

$$Y_q = \arg \max_{k=1, 2, \dots, K} \{S_q^k | S_q > 0\}.$$

Для  $q$ -го кластера,  $q=1, 2, \dots, Q$ , установить:

$$Y_q = \arg \max_{k=1, 2, \dots, K} \left\{ \sum_{p=1}^Q \left[ \frac{1}{1 + R(Y_q, Y_p)} \right] Y_p = k, S_p > 0 \right\} \left\{ S_q = 0 \right\},$$

где

$$R(Y_q, Y_p) = \frac{1}{2} \sqrt{\sum_{j=1}^N (\lambda_{q,j} - \lambda_{p,j})^2}.$$

Этап 5. Формирование термов признаков. На основе выделенных интервалов значений признаков возможно определить функции принадлежности к термам признаков на основе трапециевидной функции:

$$\mu_{i,l}(x^s) = \begin{cases} 0, x_i \leq a_{i,l}; \\ \frac{x_i - a_{i,l}}{b_{i,l} - a_{i,l}}, a_{i,l} \leq x_i \leq b_{i,l}; \\ 1, b_{i,l} \leq x_i \leq c_{i,l}; \\ \frac{d - x_i}{d - c_{i,l}}, c_{i,l} \leq x_i \leq d_{i,l}; \\ 0, d_{i,l} \leq x_i. \end{cases}$$

где  $a_{i,l} \leq b_{i,l} \leq c_{i,l} \leq d_{i,l}; a_{i,l} = (l-1)\delta + x_i^{\min}, b_{i,l} = (l-1)\delta + x_i^{\min}, c_{i,l} = l\delta + x_i^{\min}, d_{i,l} = l\delta + x_i^{\min}$ .

Этап 6. Формирование системы нечеткого вывода. На данном этапе задаются принципы преобразования значений функций принадлежности к термам в принадлежности к кластерам и классам, а также способ дефазификации результата.

Принадлежности к сформированным эталонам определим по формулам:

$$\mu^q = \min_{i=1, 2, \dots, N} \{\mu_{i,l} | \lambda_{q,i} = l\},$$

где  $q=1, 2, \dots, Q, l=1, 2, \dots, L$ .

Принадлежности к классам определим по формулам:

$$\mu_k = \max_{q=1, 2, \dots, Q} \{\mu^q | Y_q = k\}, k = 1, 2, \dots, K.$$

Расчетный номер класса, соответственно, будет определяться по формуле:

$$y^s = \arg \max_{k=1, 2, \dots, K} \{\mu_k\}.$$

Этап 7. Синтез нейро-нечеткой сети. На основе выделенных термов и определенных функций системы нечеткого вывода можно сформировать структуру нейро-нечеткой сети Мамдани [3, 4, 9, 10] в соответствии со схемой, приведенной на рис. 1.

На входной (первый) слой сети поступают входные сигналы – значения признаков распознаваемого экземпляра, которые далее поступают на второй слой, выполняющий фазификацию. Выходы нейронов второго слоя представляют собой значения функций принадлежности распознаваемого экземпляра к термам признаков. Нейроэлементы третьего слоя сети комбинируют принадлежности к термам в принадлежности к эталонам кластеров, на основе которых нейроны четвертого слоя определяют принадлежности к классам. Единственный нейрон пятого (выходного) слоя осуществляет дефазификацию и выдает на выходе расчетное значение номера класса распознаваемого экземпляра.

Этап 8. Проверка окончания поиска. Оценить ошибку для построенной сети  $E$ . Если ошибка является приемлемой ( $E < \varepsilon$ ), то завершить синтез сети и вернуть по-




Рисунок 1 – Схема нейро-нечеткой сети

лученную нейромодель как результат; в противном случае: если заданное значение  $L$  меньше, чем максимально допустимое при заданных  $N$  и  $S$ , то увеличить  $L=L+1$  и перейти к этапу 2, в противном случае – вернуть найденную нейромодель как решение.

Для обеспечения обобщающих свойств нейромодели необходимо, чтобы число ее настраиваемых параметров было меньше, чем размерность обучающей выборки  $NS$ .

Для нейро-нечеткой сети с трапециевидной функцией принадлежности к термам каждый нейрон второго слоя, соответствующий терму, будет иметь четыре настраиваемых параметра. Следовательно, общее число настраиваемых параметров нейронов второго слоя при равном числе интервалов  $L$ , на которое разбиваются диапазоны значений  $N$  входных признаков, составит  $4NL$ . Таким образом, можно сказать, что требуется, чтобы  $4NL < NS \Rightarrow L < 0,25S$ .

С другой стороны, очевидно, что диапазон значений каждого признака должен быть разбит на не менее, чем два интервала, т.е.  $L \geq 2$ . Таким образом, получаем  $2 \leq L < 0,25S$ . Данное соотношение является весьма грубым и допускает значительную неопределенность при выборе  $L$ .

Для более точной оценки интервала допустимых значений  $L$  рассмотрим полностью определенную (полносвязной прямонаправленную) нейро-нечеткую сеть, общее число весов которой  $N_w$  для обеспечения обобщающих свойств должно удовлетворять условию:  $N_w < NS$ .

Число весов в полностью определенной прямонаправленной сети оценим по формуле:

$$N_w = 4NL + NLQ + QK + K.$$

Общее число многомерных блоков определения принадлежности к кластерам может быть определено как  $Q=L^N$ . Тогда условие выбора  $L$  будет  $2 \leq L, 4NL + NLL^N + L^N K + K < NS$ .

Введя переменную  $\alpha = N / L \Rightarrow N = \alpha L$ , получим:

$$2 \leq L, 4L + LL^{\alpha L} + \frac{K(L^{\alpha L} + 1)}{\alpha L} < S.$$

Поскольку, очевидно, что  $L^{\alpha L} \gg 1$ , приняв для простоты расчетов  $K=L$ , пренебрегая меньшими слагаемыми, преобразовав и упростив полученное условие получим:

$$2 \leq L < \sqrt[N+1]{S}.$$

Из полученного соотношения легко видеть, что сокращение числа используемых признаков позволяет существенно увеличить число интервалов при поддержании обобщающих свойств модели.

Вычислительная сложность полученной нейромодели может быть оценена как  $8NL + 2NLQ + 2QK + 3K \approx O(2NL^{N+1} + 2KL^{N+1} + 8NL + 3K)$ . Пренебрегая меньшими слагаемыми, получим оценку  $O(2NL^{N+1})$ . Полагая в худшем случае  $L = \sqrt[N+1]{S}$ , получим оценку  $O(2NS)$ , а, обозначив  $n = NS$ , относительно размерности обучающей выборки  $n$  получим оценку вычислительной сложности модели  $O(n)$ .

Пространственная сложность полученной нейромодели может быть оценена как  $O(N + 4NL + NLQ + QK + K) \approx O(NL^{N+1} + L^N K + 4NL)$ . Пренебрегая меньшими слагаемыми, получим оценку пространственной сложности модели  $O(NL^{N+1})$ . Полагая в худшем случае  $L = \sqrt[N+1]{S}$ , получим оценку пространственной сложности  $O(NS) = O(n)$ .

Вычислительная сложность одного прохода предложенного метода составит  $O(26NS + SK + 2QN + 2QK + 2N + QNS + 2S + 0,5KQ^2 + 3,5Q + S(8NL + 2NLQ + 2QK + 3K))$ .

Для случая двух классов ( $K=2$ ), полагая в худшем случае  $L = \sqrt[N+1]{S}$ , получим  $O(\sqrt[N+1]{S^2} + \sqrt[N+1]{S}(2N + 7,5 + 9NS) + 2NS^2 + 4S^2 + 26NS + 10S + 2N)$ . Полагая  $S \gg N$  и пренебрегая меньшими слагаемыми, получим оценку вычислительной сложности метода  $O(S^2)$ .

Пространственная сложность метода может быть оценена как  $O(5N + 2K + QN + 2QK + 2Q + L + 4NL + NLQ)$ . Для случая двух классов ( $K=2$ ), полагая в худшем случае  $L = \sqrt[N+1]{S}$ , полагая  $S \gg N$  и пренебрегая меньшими слагаемыми, получим  $O(NS) = O(n)$ .

### ЭКСПЕРИМЕНТЫ

Предложенный метод был программно реализован как дополнение [11]. Разработанное программное обеспечение использовалось для изучения практической применимости и исследования свойств предложенного метода при решении практических задач автоматической классификации различной природы [5, 12].

При проведенні експериментів дослідувалися залежності між параметрами методу для визначення можливих обмежень на їх значення і тенденцій змінення параметрів.

### РЕЗУЛЬТАТИ

Проведені експерименти підтвердили робітоспособність і практичну применимість запропонованого методу. На рис. 1 представлені графіки отриманих залежностей.

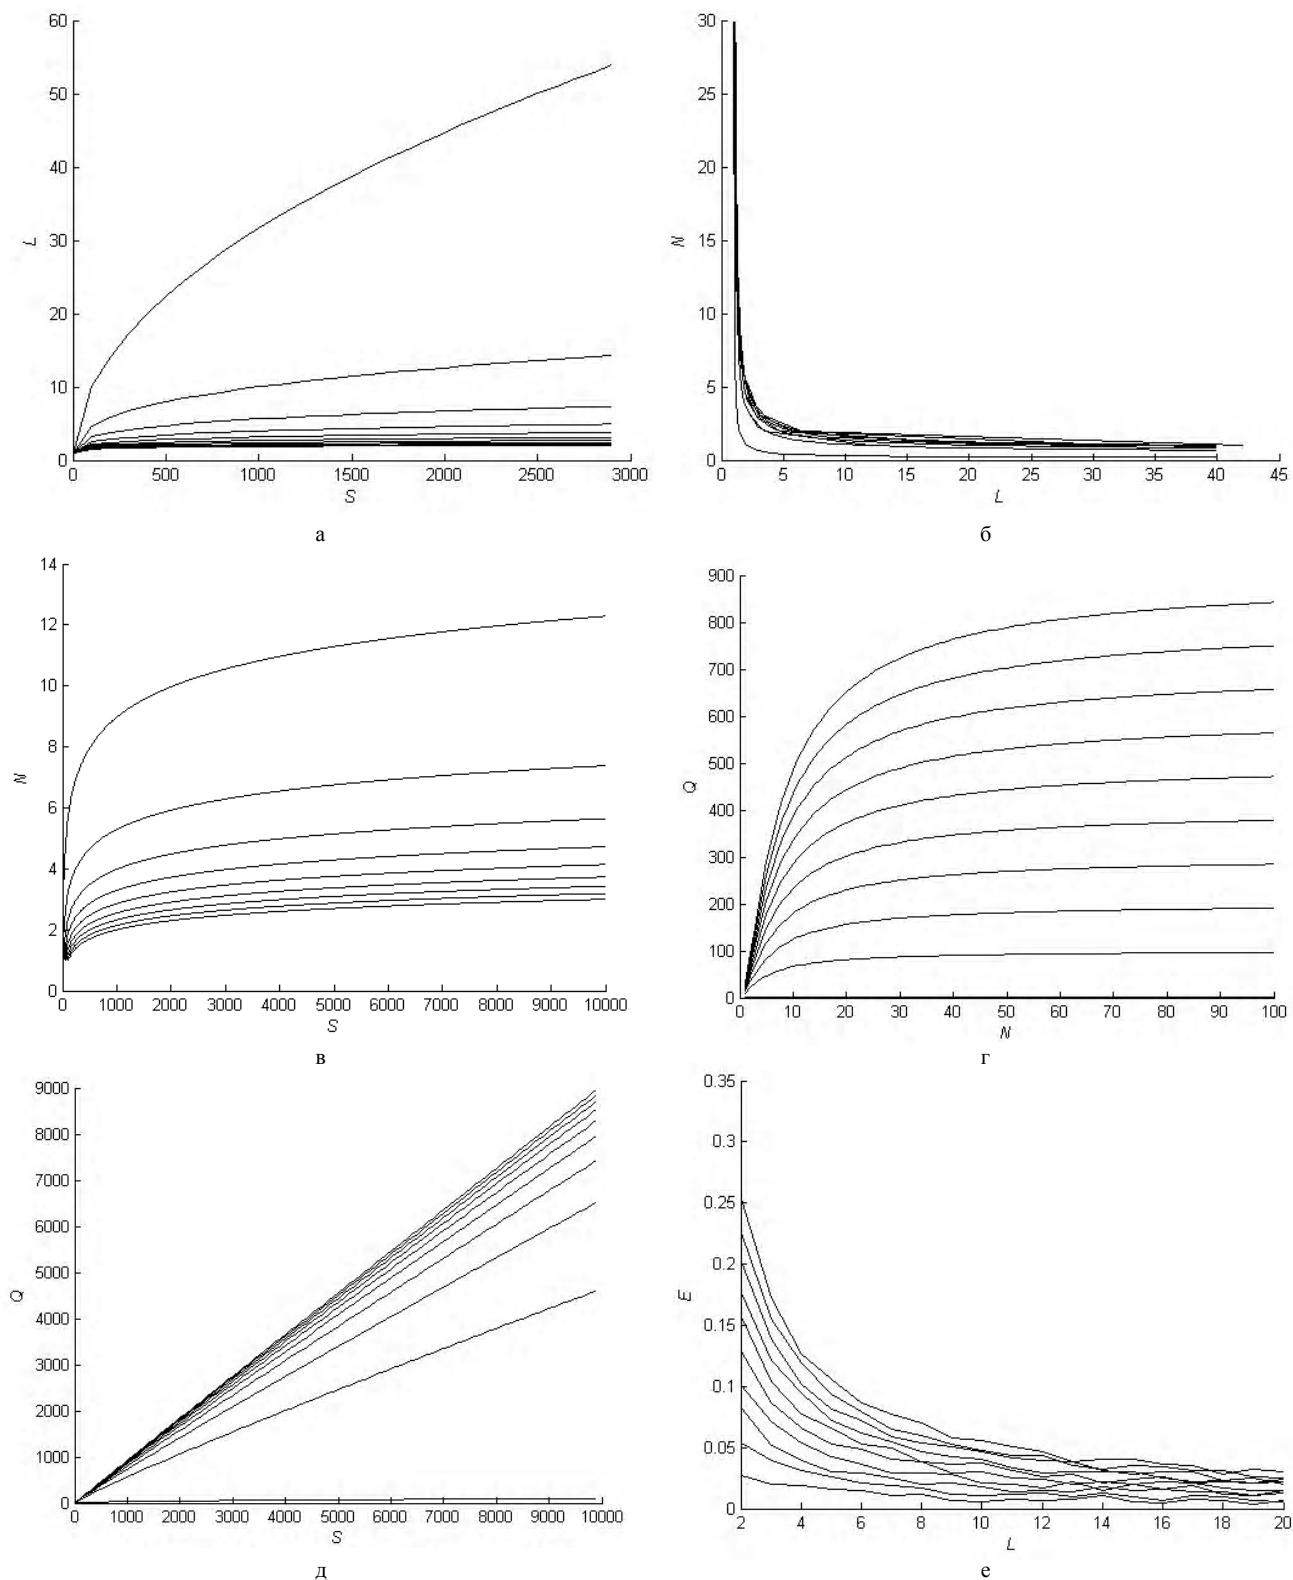


Рисунок 1 – Графіки залежностей:  
 а –  $L$  від  $S$  при різних значеннях  $N$ ; б –  $N$  від  $L$  при різних значеннях  $Q$ ;  
 в –  $N$  від  $S$  при різних значеннях  $L$ ; г –  $Q$  від  $N$  при різних значеннях  $S$ ;  
 д –  $Q$  від  $S$  при різних значеннях  $N$ ; е –  $E$  від  $L$  при різних значеннях  $N$  і  $S$

## ОБСУЖДЕНИЕ

Предложенный метод при фиксированном числе разбиений не требует загрузки всей обучающей выборки в память ЭВМ, осуществляя ее поэкземплярную обработку, не требует многократных просмотров обучающей выборки, ограничиваясь всего одним проходом при известных минимальных и максимальных значениях признаков или двумя – при неизвестных минимальных и максимальных значениях признаков.

Как видно из рис. 1а, с увеличением объема выборки наблюдается возможность увеличения предельно допустимого для сохранения обобщающих свойств значения числа интервалов, на которые разбиваются диапазоны значений признаков,  $L$ .

Однако, как следует из рис. 1а и рис. 1б, существенное ограничивающее влияние на  $L$  также имеет размерность признакового пространства  $N$ . Чем больше  $N$ , тем меньше будет возможное значение  $L$ .

С другой стороны, как видно из рис. 1в, существенное увеличение объема выборки  $S$  позволяет увеличивать допустимую границу размерности признакового пространства  $N$ . При этом, как следует из рис. 1г, с ростом  $N$  обеспечивается возможность увеличения предельно допустимого значения числа кластеров  $Q$ .

Также, как видно из рис. 1д, с ростом объема выборки  $S$  наблюдается увеличение предельно допустимого значения числа кластеров  $Q$ .

Как следует из рис. 1е, с ростом числа разбиений признаков  $L$  при фиксированных  $S$  и  $N$  для каждой из выборок наблюдается в среднем уменьшение ошибки  $E$ . Это уменьшение особенно существенно на начальном этапе и становится незначительным при достижении числа разбиений интервалов значений признаков, обеспечивающих создание такого числа кластеров  $Q$ , которое сопоставимо с числом экземпляров в выборке  $S$ .

Следовательно, для больших по объему выборок данных, если необходимо обеспечить высокий уровень обобщения данных моделью, следует предварительно выполнить отбор наиболее информативных признаков, минимизируя размерность признакового пространства  $N$ . Это позволит увеличить допустимую границу  $L$  и обеспечить большую точность (меньшую ошибку  $E$ ).

## ВЫВОДЫ

В работе решена актуальная проблема автоматизации синтеза моделей для классификации образов по признакам.

Научная новизна работы состоит в том, что впервые предложен метод синтеза нейро-нечетких моделей по прецедентам, способный получать полностью определенные нейромодели на основе регулярного разбиения признаков. Метод рассчитывает координаты центров кластеров как координаты центров прямоугольных блоков в пространстве интервалов признаков, а принадлежности кластеров к классам определяет по обучающей выборке: для кластеров, покрытых наблюдениями, принадлежность определяется по максимуму частоты экземпляров соответствующих классов в кластере, а для кластеров, не покрытых наблюдениями, принадлежность определяется по максимальному потенциалу, наводимому

на данный кластер кластерами с известной принадлежностью к классам. Полученный набор кластеров-правил отображается в структуру нейро-нечеткой сети Мамдани, а ее параметры настраиваются на основе параметров разбиения признаков и центров кластеров. Предложенный метод не требует загрузки всей обучающей выборки в память ЭВМ и существенно ускоряет процесс синтеза моделей, обеспечивая при этом приемлемый уровень обобщения данных получаемой нейромоделью.

Практическая значимость результатов работы заключается в том, что разработано программное обеспечение, реализующее предложенный метод, а также проведены эксперименты, подтвердившие работоспособность разработанного математического обеспечения и позволяющие рекомендовать его для использования на практике при решении задач построения нейро-нечетких моделей для выборок большого объема.

Перспективы дальнейших исследований состоят в исследовании предложенного математического обеспечения на более широком наборе практических задач диагностики и распознавания образов.

## БЛАГОДАРНОСТИ

Работа выполнена в рамках в рамках госбюджетных научно-исследовательской темы Запорожского национального технического университета «Методи і засоби обчислювального інтелекту та паралельного комп'ютерингу для оброблення великих даних в системах діагностування» при поддержке международного проекта «Centers of Excellence for young REsearchers» программы «Темпус» Европейской Комиссии (№ 544137-TEMPUS-1-2013-1-SK-TEMPUS-JPHES).

## СПИСОК ЛИТЕРАТУРЫ

1. Analysis and design of intelligent systems using soft computing techniques / eds. : P. Melin, O.R. Castillo, E.G. Ramirez, J. Kacprzyk. – Heidelberg : Springer, 2007. – 855 p.
2. Buckleya J. J. Fuzzy neural networks: a survey / J. J. Buckleya, Y. Hayashi // Fuzzy sets and systems. – 1994. – Vol. 66, Issue 1. – P. 1–13.
3. Дли М. И. Нечеткая логика и искусственные нейронные сети / М. И. Дли. – М. : Физматлит, 2003. – 225 с.
4. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилинский, Л. Рутковский ; пер. с польск. И. Д. Рудинского. – М. : Горячая линия – Телеком, 2004. – 452 с.
5. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов : монография / [С. А. Субботин, Ан. А. Олейник, Е. А. Гофман, С. А. Зайцев, Ал. А. Олейник] ; под ред. С. А. Субботина. – Харьков : Компания СМІТ, 2012. – 318 с.
6. Осовский С. Нейронные сети для обработки информации / С. Осовский. – М. : Финансы и статистика, 2004. – 344 с.
7. Фор А. Восприятие и распознавание образов / А. Фор ; под ред. Г. П. Катгса. – М. : Машиностроение, 1989. – 271 с.
8. Айзерман М. А. Метод потенциальных функций в теории обучения машин / М. А. Айзерман, Э. М. Браверман, Л. И. Розоноэр. – М. : Наука, 1970. – 384 с.
9. Ярушкина Н. Г. Основы теории нечетких и гибридных систем / Н. Г. Ярушкина. – М. : Финансы и статистика, 2004. – 320 с.
10. Яхьяева Г. Э. Нечеткие множества и нейронные сети : учеб. пособие / Г. Э. Яхьяева. – М. : Интуит, 2006. – 316 с.
11. Комп'ютерна програма «Автоматизована система синтезу нейромрежних та нейро-нечітких моделей для неруйнівної

діагностики та класифікації образів за ознаками»: свідоцтво про реєстрацію авторського права на твір № 35431 / С. О. Субботін. – Держ. департамент інтелектуальної власності. – № 34011 ; заявл. 21.04.10 ; зареєстр. 21.10.10.

12. Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла

авиационных двигателей : монография / [А. В. Богуслаев, Ал. А. Олейник, Ан. А. Олейник, Д. В. Павленко, С. А. Субботин]; под ред. Д. В. Павленко, С. А. Субботина. – Запорожье : ОАО «Мотор Сич», 2009. – 468 с.

Статья поступила в редакцию 01.09.2016.  
После доработки 25.09.2016.

Субботін С. О.

Д-р техн. наук, професор, професор кафедри програмних засобів Запорізького національного технічного університету, Запоріжжя, Україна

#### ПОБУДОВА ПОВНІСТЮ ВИЗНАЧЕНИХ НЕЙРО-НЕЧІТКИХ МЕРЕЖ З РЕГУЛЯРНИМИ РОЗБИТТЯМ ПРОСТОРУ ОЗНАК НА ОСНОВІ ВИБІРОК ВЕЛИКОГО ОБСЯГУ

Вирішено проблему автоматизації синтезу моделей для класифікації образів за ознаками. Запропоновано метод синтезу нейро-нечітких моделей за прецедентами, здатний одержувати цілком визначені нейромоделі на основі регулярного розбиття ознак. Метод розраховує координати центрів кластерів як координати центрів прямокутних блоків у просторі інтервалів ознак, а належності кластерів до класів визначає за навчальною вибіркою: для кластерів, покритих спостереженнями, належність визначається за максимумом частоти екземплярів відповідних класів у кластері, а для кластерів, не покритих спостереженнями, належність визначається за максимальним потенціалом, що наводиться на даний кластер кластерами з відомою належністю до класів. Отриманий набір кластерів-правил відображається у структуру нейро-нечіткої мережі Мамдани, а її параметри налаштовуються на основі параметрів розбиття ознак і центрів кластерів. Запропонований метод не вимагає завантаження всієї навчальної вибірки в пам'ять ЕОМ та істотно прискорює процес синтезу моделей, забезпечуючи при цьому прийнятний рівень узагальнення даних одержуваною нейромоделлю. Розроблено програмне забезпечення, що реалізує запропонований метод, а також проведені експерименти, що підтвердили працездатність розробленого математичного забезпечення і що дозволяють рекомендувати його для побудови нейро-нечітких моделей на основі вибірок великого обсягу.

**Ключові слова:** нейро-нечітка мережа, навчання, синтез, класифікація.

Subbotin S. A.,

Dr.Sc., Professor, Chief of the department of software tools, Zaporizhzhya National Technical University, Zaporizhzhya, Ukraine

#### BUILDING A FULLY DEFINED NEURO-FUZZY NETWORK WITH A REGULAR PARTITION OF A FEATURE SPACE BASED ON LARGE SAMPLE

The problem of model synthesis automation for pattern classification on the features is solved. The method of neuro-fuzzy model synthesis on precedents is proposed. It is able to construct completely defined neural models based on the regular partition of a feature space. The method calculates the coordinates of the cluster centers as coordinates of the centers of rectangular blocks in the space of feature intervals and clusters membership to classes determine on the training set: for clusters containing observations the membership is determined by the maximum frequency of instances of the corresponding classes in the cluster, and for clusters that do not contain observations the membership is determined by the maximum potential induced on it by the clusters with known class membership. The resulting set of clusters-rules is mapped to the structure of Mamdani neuro-fuzzy network and its parameter values are calculated on the base of parameters of feature set partition and cluster centers. The proposed method does not require loading the entire training sample in the computer memory and speeds up the process of model synthesis providing an acceptable level of data generalization by obtained neural model. The software that implements the proposed method is developed. The experiments confirming the performance of developed mathematical support are conducted. They allow to recommend the method for the construction of neuro-fuzzy models based on a large samples.

**Keywords:** neuro-fuzzy network, training, synthesis, classification.

#### REFERENCES

1. Melin P., Castillo O.R., Ramirez E.G., Kacprzyk J. : eds. Analysis and design of intelligent systems using soft computing techniques. Heidelberg, Springer, 2007, 855 p.
2. Buckley J. J., Hayashi Y. Fuzzy neural networks: a survey, *Fuzzy sets and systems*, 1994, Vol. 66, Issue 1, pp. 1–13.
3. Dli M. I. Nechotkaya logika i iskusstvennyye neyronnyye seti. Moscow, Fizmatlit, 2003, 225 p.
4. Rutkovskaya D., Pilin'skiy M., Rutkovskiy L.; per. s pol'sk. I. D. Rudinskogo Neyronnyye seti, geneticheskiye algoritmy i nechotkiye sistemy. Moscow, Goryachaya liniya, Telekom, 2004, 452 p.
5. Subbotin S. A., Oleynik An. A., Gofman Ye. A., Zaytsev S. A., Oleynik Al. A. ; pod red. S. A. Subbotina Intellektual'nyye informatsionnyye tekhnologii proyektirovaniya avtomatizirovannykh sistem diagnostirovaniya i raspoznavaniya obrazov : monografiya. Khar'kov, Kompaniya SMIT, 2012, 318 p.
6. Osovskiy S. Neyronnyye seti dlya obrabotki informatsii. Moscow, Finansy i statistika, 2004, 344 p.
7. For A. ; pod red. G. P. Katysa Vospriyatiye i raspoznavaniye obrazov. Moscow, Mashinostroyeniye, 1989, 271 p.
8. Ayzerman M. A., Braverman E. M., Rozonoer L. I. Metod potentsial'nykh funktsiy v teorii obucheniya mashin. Moscow, Nauka, 1970, 384 p.
9. Yarushkina N. G. Osnovy teorii nechotkikh i gibridnykh sistem. Moscow, Finansy i statistika, 2004, 320 p.
10. Yakh'yayeva G. E. Nechotkiye mnozhestva i neyronnyye seti : ucheb. posobiye. Moscow, Intuit, 2006, 316 p.
11. Subbotin S. O. Komp'yuterna prohrama "Avtomatyzovana systema syntezu neyromerezhevykh ta neyro-nechitkykh modeley dlya neruynivnoyi diahnostryky ta klasyfikatsiyi obraziv za oznakamy" :ovidotstvo pro reyestratsiyu avtorskoho prava na tvir № 35431. Derzh. departament intelektual'noyi vlasnosti. № 34011 ; zayavl. 21.04.10 ; zareyestr. 21.10.10.
12. Boguslayev A. V., Oleynik Al. A., Oleynik An. A., Pavlenko D. V., Subbotin S. A.; pod red. D. V. Pavlenko, S. A. Subbotina. Progressivnyye tekhnologii modelirovaniya, optimizatsii i intellektual'noy avtomatizatsii etapov zhiznennogo tsikla aviatsionnykh dvigateley : monografiya. Zaporozh'ye: ОАО "Motor Sich", 2009, 468 p.