





специализированной базы данных, с перенесением на исследуемый фрагмент характеристик ближайшего паттерна из специализированной базы данных; применение сложной комбинации методов анализа случайных процессов и многомерного статистического анализа.

**Ключевые слова:** операторы сложных технических систем, интеллектуальная поддержка экипажа, оценка уровня подготовки экипажа, видеоокулография, метрика правдоподобия, метрика Кохонена.

**Для цитаты:**

*Грешников И.И., Куравский Л.С., Юрьев Г.А.* Принципы построения программно-аппаратного комплекса для интеллектуальной поддержки экипажа и оценки уровня его подготовки // Моделирование и анализ данных. 2021. Том 11. № 2. С. 5–30. DOI: <https://doi.org/10.17759/mda.2021110201>

**\*Грешников Иван Игоревич**, начальник сектора, Государственный научно-исследовательский институт авиационных систем (ФГУП «ГосНИИАС»), г. Москва, Российская Федерация, ORCID: <https://orcid.org/0000-0001-5474-3094>, e-mail: [vvanes@mail.ru](mailto:vvanes@mail.ru)

**\*\*Куравский Лев Семёнович**, доктор технических наук, профессор, декан факультета «Информационные технологии», заведующий кафедрой «Прикладная информатика и мультимедийные технологии», Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация, ORCID: <http://orcid.org/0000-0002-3375-8446>, e-mail: [l.s.kuravsky@gmail.com](mailto:l.s.kuravsky@gmail.com)

**\*\*\*Юрьев Григорий Александрович**, кандидат физико-математических наук, доцент, профессор кафедры прикладной информатики и мультимедийных технологий, заместитель декана факультета информационных технологий по научной работе, заведующий лабораторией математической психологии и прикладного программного обеспечения центра информационных технологий для психологических исследований, Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация, ORCID: <https://orcid.org/0000-0002-2960-6562>, e-mail: [g.a.yuryev@gmail.com](mailto:g.a.yuryev@gmail.com)

## 1. ВВЕДЕНИЕ

Проблема оценки влияния человеческого фактора (ЧФ) при проектировании и эксплуатации авиационной техники признается всеми исследователями и регулирующими органами авиационной отрасли. На сегодняшний день ЧФ становится одной из основных причин возникновения критических ситуаций в полете воздушного судна (ВС). Как правило, ошибки совершаются экипажем в результате неправильной оценки текущей ситуации.

Тем не менее, в настоящее время ЧФ и его влияние на развитие критических ситуаций в полете все еще недостаточно учитывается на этапах анализа безопасности и проектирования кабины экипажа ВС. Современный подход к учету ЧФ базируется только на анализе статистики произошедших инцидентов и происшествий, что является основным его недостатком. В результате, существующие методики и рекомендации, учитывающие ЧФ, направлены лишь на изменения в процессах обучения опе-



раторов или процедурах эксплуатации плохо спроектированных систем и устройств, не позволяя количественно оценивать риски в конкретных полётах и выявлять факторы, способствующие возникновению опасных лётных ситуаций. Проблема заключается, во-первых, в отсутствии моделей рисков и недостатке статистических данных о ЧФ, полученных в результате исследования инцидентов безопасности, и, во-вторых, в отсутствии эффективных научно-практически обоснованных мер по смягчению этих рисков при проектировании кабины экипажа ВС. Разработка математических моделей и методов оценки уровня подготовки экипажа на основе анализа параметров полета, а также их программная реализация позволят существенно продвинуться в развитии средств прогнозирования рисков и выявления факторов, способствующих возникновению опасных лётных ситуаций, в том числе в режиме реального времени.

К настоящему времени получен ряд результатов, связанных с выявлением проблем пилотирования [1–10, 15–20], где в подавляющем большинстве случаев рассматриваются только параметры траектории воздушного судна и не учитываются другие характеристики. Ограничения, которые делают невозможным реальное практическое применение этих результатов, детально рассмотрены в работах [12–14]. Следует отметить, что многие из указанных ограничений обусловлены применением традиционных метрик для сравнения фрагментов полетов (манёвров).

В данной статье рассмотрен новый подход к обеспечению интеллектуальной поддержки и оценки уровня подготовки экипажа, опирающийся на результаты, представленные в работах [11–14]. Особенности представленного подхода являются:

- наличие «интеллектуальной составляющей», которая содержится в эмпирических данных и может гибко изменяться по мере их накопления;
- применение интегральных сравнений исследуемых фрагментов полета и данных видеоокулографии с сопоставимыми образцами различных типов и качества исполнения из специализированной базы данных, содержащей паттерны нормального и аномального пилотирования; при этом на исследуемый фрагмент переносятся характеристики ближайшего паттерна из специализированной базы данных;
- применение сложной комбинации методов анализа случайных процессов и многомерного статистического анализа.

При этом используются экспериментальные данные, включающие комбинированную информацию о динамике полёта и управлении воздушным судном, распределении визуального внимания пилотов, а также экспертные оценки результатов выполнения лётных упражнений.

Ключевым компонентом данного подхода являются рассматриваемые в этой статье четыре новые сложные метрики, обеспечивающие значимую дискриминацию анализируемых фрагментов полётов и данных видеоокулографии различных типов и качества исполнения, а именно: евклидова метрика в пространстве вейвлет-коэффициентов, метрика правдоподобия траекторий собственных значений преобразований параметров деятельности, метрика Кохонена в пространстве вейвлет-коэффициентов (с использованием ассоциативных нейронных сетей) и метрика правдоподобия для сравнения траекторий движения взора. Известные ранее метрики этот результат не обеспечивают.



Рассмотренные далее результаты являются существенным шагом в развитии средств прогнозирования рисков и выявления факторов, способствующих возникновению опасных лётных ситуаций, в том числе в режиме реального времени, и могут применяться:

- для оценки работы экипажей, включая контроль качества их обучения,
- поддержки формирования инструкторских оценок,
- обеспечения современных форм адаптивного обучения экипажей,
- сравнения различных форматов системы экранной индикации в кабине экипажа,
- оптимизации компоновки индикаторов кабины экипажа воздушного судна с учетом данных видеоокулографии,
- оценки влияния компоновки индикаторов кабины экипажа воздушного судна и условий полёта на риски возникновения авиационных инцидентов,
- сравнения различных средств и программ обучения лётного состава, а также при проектировании современных летательных аппаратов.

## **2. ИНТЕЛЛЕКТУАЛЬНАЯ ПОДДЕРЖКА ЭКИПАЖА В РАМКАХ ПРОЦЕДУРЫ ОБУЧЕНИЯ ЭКИПАЖА НА ТРЕНАЖЁРАХ И УПРАВЛЕНИЯ ВОЗДУШНЫМ СУДНОМ: ОБЩЕЕ ОПИСАНИЕ**

Интеллектуальная поддержка экипажа может обеспечиваться как на авиационных тренажёрах и стендах в процессе обучения, так и в реальном полёте. Структура связей модуля интеллектуальной поддержки с компонентами процедуры обучения на тренажёрах/стендах и управлением воздушным судном представлена на рис. 1. Интеллектуальная поддержка выполняется в реальном времени и реализуется тремя компонентами программного обеспечения:

- инструментальным средством «The Intelligent System for Flight Analysis» (ISFA), обеспечивающим применение предусмотренных математических моделей и методов,
- монитором состояния полёта (Flight Condition Monitor) и
- модулем формирования фрагментов полёта.

Инструментальное средство ISFA вычисляет свои оценки на основе динамически получаемой информации о параметрах полёта и состоянии систем воздушного судна (ВС), а также используя данные видеоокулографии, представленные траекториями движения взоров пилотов, которые измеряются с помощью айтрекера.

Применяемая концепция оценивания опирается на интегральные сравнения исследуемых фрагментов полёта и действий пилотов с сопоставимыми фрагментами из специализированной базы данных, содержащей паттерны, характеризующие выполнение лётных упражнений экипажами с различным уровнем подготовки, включая нормальное и аномальное пилотирование. На оцениваемый фрагмент переносятся характеристики ближайшего паттерна. Таким образом, «интеллект» системы, принимающей решения, содержится в накопленных эмпирических данных и может усиливаться по мере наполнения базы паттернами.



Монитор состояния полёта обеспечивает вывод диагностической информации, полученной системой ISFA в результате оперативно проведённого анализа, для экипажа и пилотов-инструкторов. На основе этой информации оценивается качество пилотирования и формируются сообщения, которые предупреждают экипаж об опасности, обусловленной аномальным пилотированием – если она имеет место – и сообщают экипажу информацию, позволяющую понять, в чём заключались его ошибки при выполнении заданного манёвра. Кроме того, в рамках процедуры обучения, опираясь на информацию, выведенную на монитор, пилот-инструктор формирует новые задания для экипажа.

На монитор состояния полёта выводятся сведения о нормальности или аномальности выполняемого маневра, распознанный тип маневра, текстовое описание выявленной аномальности маневра – если она имеет место – и процентный вклад наиболее значимых с точки зрения анализа лётных параметров, которыми обусловлены отличия оцениваемого фрагмента полёта от эталонного выполнения манёвра данного типа.

При достаточно квалифицированном наполнении специализированной базы данных характерными фрагментами (паттернами) полётов, оценки, формируемые на панели монитора, фактически обеспечивают замену «субъективного инструктора» (т.е. человека, оценивающего действия и состояния экипажа на основе своего индивидуального опыта, с сопутствующими пристрастиями и вариативностью индивидуальных представлений об объекте оценивания) на «объективного инструктора», оценивающего всех в единой шкале и не имеющего ни пристрастий, ни вариативности представлений.

Информация, выводимая на панель монитора и доступная пилотам, поддерживает «обратную связь», позволяющую экипажу корректировать свои действия. Она включает и сигналы об опасностях, содержащие более детализированные сведения, чем те, которые обычно принято доводить для пилотов в кабине самолёта. Выводимая на панель монитора текстовая информация, а также сведения о вкладе наиболее значимых параметров, которыми обусловлены отличия оцениваемого фрагмента полёта от эталонного паттерна, позволяют пилотам понять причины ошибок пилотирования, если они имеют место.

### **3. МАТЕМАТИЧЕСКИЕ МОДЕЛИ И МЕТОДЫ, ОБЕСПЕЧИВАЮЩИЕ ИНТЕЛЛЕКТУАЛЬНУЮ ПОДДЕРЖКУ И ОЦЕНКУ УРОВНЯ ПОДГОТОВКИ И СОСТОЯНИЯ ЭКИПАЖА**

Оценки уровня подготовки и состояния экипажа и элементы его интеллектуальной поддержки строятся на основе анализа наборов временных рядов, описывающих динамику параметров летательного аппарата, состояние пилотов и их глазодвижительную активность, представленную данными видеоокулографии. Данные для анализа поступают в процессе выполнения лётных упражнений.

Алгоритмические аспекты применяемого подхода представлены диаграммой потоков данных на рис. 2.




Рис. 1. Обеспечение интеллектуальной поддержки экипажа в реальном времени при управлении воздушным судном и обучении на тренажёрах

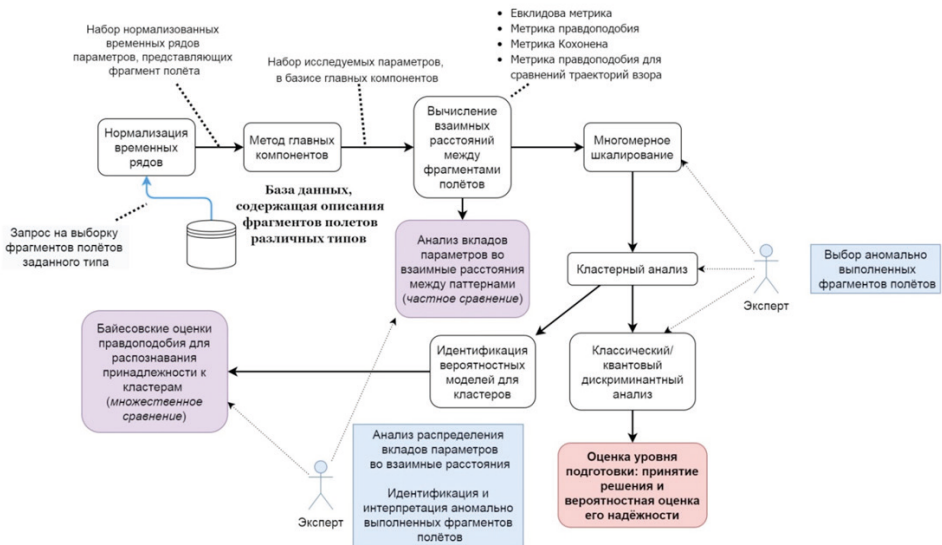


Рис. 2. Диаграмма потоков данных, представляющая алгоритмические аспекты оценки уровня подготовки и состояния экипажа

Оценки уровня подготовки экипажа определяются на основе интегральных сравнений исследуемых фрагментов полёта или поведения сложной системы с сопоставимыми фрагментами (паттернами) из специализированной базы данных, которые характеризуют выполнение лётных упражнений экипажами с различным уровнем подготовки. Паттерны представляют характерные фрагменты полётов с помощью наборов временных рядов, которые содержат значения параметров, определяющих движение и состояние систем летательного аппарата. На исследуемый фрагмент полёта переносятся характеристики паттерна, ближайшего в заданной метрике. Определение ближайшего паттерна сопровождается распознаванием anomalously пилотирования и определением параметров полёта, характеризующих ошибки экипажа. Anomalously фрагментов полёта выявляется через принадлежность к заданным кластерам паттернов. При этом выявляются параметры, ответственные за принадлежность к определённым кластерам, а также за различия между паттернами.

Информация, собранная в специализированной базе данных, включает в себя временные ряды, содержащие значения параметров выполнения упражнений, а также комментарии, содержащие экспертные оценки. Эти оценки содержат информацию об ошибках экипажа в терминах параметров деятельности. Временные ряды приводятся к единой шкале.

Результаты сравнения фрагментов полёта и данных видеоокулографии с сопоставимыми паттернами из специализированной базы данных вычисляются в результате анализа трех типов характеристик: параметров полёта и состояния систем воздушного судна; траекторий движения глаз пилотов; временных рядов первичных показателей глазодвигательной активности пилотов.



Действия, реализуемые пилотами с разным профессиональным качеством выполнения, а также фрагменты полётов разных типов отделяются друг от друга в достаточной степени в многомерном пространстве шкалирования, сформированном с помощью специальной процедуры в подобранных метриках. Это утверждение опирается на результаты проведённых вычислительных экспериментов. Результат решения задачи определяется выбором паттернов.

Необходимый результат достигается применением сложной комбинации процедур анализа случайных процессов и многомерного статистического анализа. «Интеллект» средств распознавания содержится в эмпирических данных, представленных паттернами, и может гибко изменяться по мере их накопления. Эмпирические данные включают комбинированную информацию о динамике полёта и управлении воздушным судном, о распределении визуального внимания пилотов, а также экспертные оценки результатов выполнения лётных упражнений.

Используя результаты применения метода главных компонент, многомерного шкалирования и кластерного анализа параметров полёта, состояния систем воздушного судна и траекторий движения глаз пилотов, формируются кластеры фрагментов полетов различных типов и качества исполнения, которые используются для классификации маневров в пространстве шкалирования, выявления ошибок экипажа и получения оценок качества выполнения исследуемых фрагментов полетов.

При этом:

- метод главных компонент понижает размерность задачи и обеспечивает определение представителей групп параметров с высокой внутренней корреляцией;
- многомерное шкалирование обеспечивает разделение в пространстве шкалирования паттернов различных типов фрагментов полётов и глазодвижительной активности пилотов, а также нормальных/аномальных результатов деятельности;
- кластерный анализ обеспечивает разделение различных типов и уровней качества выполнения фрагментов полётов;
- дискриминантный анализ решает задачи классификации фрагментов полётов.

Итоговые заключения о принадлежности к целевым кластерам, связанным с типами упражнений и качеством пилотирования, строятся на основе вычисления вероятностного профиля, что обеспечивается средствами дискриминантного анализа. Для содержательного анализа причин некорректного выполнения маневров детализируются относительные вклады параметров полёта и состояния систем воздушного судна в элементы матриц взаимных расстояний между фрагментами полётов в заданной метрике, что позволяет определять параметры, характеризующие ошибки пилота, с целью выявления их причин. При достаточной скорости компьютерных вычислений, оценки уровня подготовки экипажа могут быть получены в автоматическом режиме в реальном времени.

Количественные оценки уровня подготовки экипажей определяются тремя способами:

- путём прямого сравнения исследуемых фрагментов полётов с паттернами деятельности из базы данных, используя одну из применяемых метрик (при этом на исследуемое упражнение переносятся характеристики ближайшего паттерна);





- с помощью вероятностных оценок, вычисленных средствами дискриминантного анализа, используя выборочные функции распределения расстояний упражнений до центров кластеров в пространстве шкалирования;
- с помощью вероятностного профиля пребывания в диапазонах параметров деятельности, используя байесовские оценки правдоподобия.

При этом эксперт, принимающий участие в процедуре анализа результатов выполнения лётных упражнений, отвечает за:

- выбор кластеров аномальных паттернов в пространстве шкалирования;
- анализ баланса вкладов параметров при сравнении упражнений с целью выбора релевантных параметров для дальнейшего исследования;
- выявление и интерпретацию аномалий и ошибок.

Рассматриваемый подход можно применять даже при малых выборках лётных упражнений, поскольку и в этом случае можно выбрать паттерн и рассчитать вклад параметров во взаимные расстояния.

Представленные в отчёте [21] результаты практического применения показали, что разработанные методы обеспечили способность к распознаванию аномально выполненных фрагментов полетов и определению параметров, характеризующих ошибки пилота, с последующей возможностью выявления их причин.

Применяемый подход содержит следующие элементы новизны:

- вместо непосредственного представления исследуемых процессов временными рядами используется их представление вейвлет-коэффициентами, полученными в результате дискретного вейвлет-преобразования, что сняло проблему синхронизации сопоставляемых процессов, существенно тормозившую работы в данном направлении;
- основной формой представления анализируемых данных являются матрицы взаимных расстояний исследуемых процессов в различных метриках;
- в зависимости от типа задачи, применяются четыре вновь разработанные метрики для сравнения исследуемых фрагментов полётов;
- представление фрагментов полетов в пространстве шкалирования и их распределение по типам путем применения многомерного шкалирования к матрицам взаимных расстояний и последующего кластерного анализа;
- оценка относительных вкладов параметров в элементы матриц взаимных расстояний между фрагментами полётов и байесовские оценки правдоподобия с целью выявления аномально выполненных маневров и определения параметров, динамика которых свидетельствует об ошибках пилотов.

Для регистрации глазо двигательной активности применяются бесконтактные технические средства – *айтрекеры*, которые позволяют исключить субъективную оценку показателей состояния пилотов.

Разработанный подход продемонстрировал способность к распознаванию аномально выполненных фрагментов полетов и определению параметров, характеризующих ошибки пилота, обеспечивая таким образом последующее выявление их причин.

Практическое применение разработанного подхода обеспечивается инструментальным средством «*The Intelligent System for Flight Analysis*» (*ISFA*), предназначен-



ным для анализа поведения сложных систем. Это средство первоначально разрабатывалось для оценки качества выполнения лётных маневров, однако позднее стало применяться и для анализа данных видеоокулографии.

## **4. МЕТРИКИ, ОБЕСПЕЧИВАЮЩИЕ СРАВНЕНИЕ АНАЛИЗИРУЕМЫХ ФРАГМЕНТОВ ПОЛЁТОВ И ДАННЫХ ВИДЕООКУЛОГРАФИИ РАЗЛИЧНЫХ ТИПОВ И КАЧЕСТВА ИСПОЛНЕНИЯ**

### **4.1. Сравнение фрагментов полётов, используя евклидову метрику в пространстве вейвлет-коэффициентов**

Размерность матриц взаимных расстояний между фрагментами полётов равна объёму выборки исследуемых фрагментов. Исходные временные ряды, представляющие исследуемые процессы, при сравнении заменяются на ряды вейвлет-коэффициентов, полученных в результате кратномасштабного анализа [6]. При этом исходные процессы как функции времени заменяются интегральными характеристиками временных интервалов, которые относятся к области определения этих функций, что позволяет обеспечить значительное сокращение (примерно на порядок величины) количества коэффициентов, необходимых для правильного представления анализируемых процессов. Благодаря правилам соотнесения вейвлет-коэффициентов с фрагментами временных рядов, которые применяются в кратномасштабном анализе, преодолеваются трудности, связанные с необходимостью точной синхронизации процессов, относящихся к различным фрагментам полётов одного типа, поскольку наиболее значимые коэффициенты, относящиеся к более продолжительным временным интервалам, практически не чувствительны к умеренным сдвигам во времени. Длина вейвлет-представлений, используемых при последующем анализе, существенно (примерно на порядок величины) меньше длины соответствующего исходного временного ряда, при этом точность оценок существенно не ухудшается. Матрицы взаимных расстояний, вычисленные для всех рассматриваемых параметров, складываются, в результате чего получается общая матрица взаимных расстояний между исследуемыми фрагментами полётов.

Применяемый кратномасштабный анализ (КМА) (*Multiresolution Analysis, MRA*) – это инструмент для разделения сигналов на составляющие и анализа их порядка. Сигнал рассматривается в виде суммы разнотипных составляющих: функции тренда (средних значений по большим интервалам), циклических компонентов с определенным периодом повторения, локальных особенностей разного порядка (вплоть до скачков в определенные моменты), флюктуаций более высокого порядка вокруг перечисленных выше составляющих сигнала. Понятие КМА является фундаментальным в теории вейвлетов благодаря каскадному алгоритму вычислений, подобному быстрому преобразованию Фурье.

Детальное описание процедуры формирования матрицы взаимных расстояний в евклидовой метрике в пространстве вейвлет-коэффициентов представлено в [21].

## 4.2. Сравнение фрагментов полётов, используя метрику правдоподобия траекторий собственных значений для преобразований параметров деятельности

Описание метрики правдоподобия траекторий собственных значений для преобразований параметров фрагментов полётов представлено в работе [4].

Рассмотрим множество, состоящее из  $M$  зависимых от времени параметров выполнения фрагмента полёта, представленных наборами временных рядов:

$$\mathbf{r}_i = (r_{i,1}, r_{i,2}, \dots, r_{i,M})^T,$$

где значения индекса  $i \in \{1, 2, \dots, N\}$  соответствуют дискретным моментам времени. Динамика  $r_i$  может быть представлена следующим матричным уравнением:

$$\mathbf{r}_{i+1} = \mathbf{F}_i \mathbf{r}_i,$$

где  $\mathbf{F}_i$  – зависящая от времени матричная функция размерности  $M$ , которую следует идентифицировать по экспериментальным данным.

Для достаточно короткого интервала времени, включающего  $K$  точек и начинающегося в момент  $t_0$ , где  $K \geq M$ , матрицу  $\mathbf{F}_i$  можно аппроксимировать соответствующей стационарной матрицей:

$$\mathbf{F}_{i_0+j} \equiv \mathbf{F}_{i_0}, \text{ для всех } j \in \{0, 1, \dots, K-1\}.$$

Временной шаг, используемый при формировании рассматриваемого временного ряда, может варьироваться до достижения необходимого уровня согласования с экспериментальными данными.

Если рассмотреть  $K$  уравнений

$$\left\{ \mathbf{r}_{i+1} = \mathbf{F}_{i_0} \mathbf{r}_i \right\}_{i \in \{i_0, i_0+1, \dots, i_0+K-1\}}, \text{ где } \mathbf{F}_{i_0} = \begin{pmatrix} f_{i_0,11} & \dots & f_{i_0,1M} \\ \vdots & \ddots & \vdots \\ f_{i_0,M1} & \dots & f_{i_0,MM} \end{pmatrix} = \begin{pmatrix} \mathbf{f}_{i_0,1}^T \\ \dots \\ \mathbf{f}_{i_0,M}^T \end{pmatrix},$$

то каждую строку  $\mathbf{f}_{i_0,l}^T$ ,  $l \in \{1, \dots, M\}$  матрицы  $\mathbf{F}_{i_0}$  можно идентифицировать как псевдорешение соответствующего  $l$ -го матричного уравнения, которое в общем случае является переопределенным:

$$\mathbf{Q}_{i_0} \mathbf{f}_{i_0,l} = \mathbf{q}_{i_0+1,l},$$

$$\text{где } \mathbf{Q}_{i_0} = \begin{pmatrix} r_{i_0,1} & \dots & r_{i_0,M} \\ \vdots & \ddots & \vdots \\ r_{i_0+K-1,1} & \dots & r_{i_0+K-1,M} \end{pmatrix}, \mathbf{q}_{i_0+1,l} = (r_{i_0+1,l}; r_{i_0+2,l}; \dots; r_{i_0+K,l}).$$

Каждое из указанных  $l$  переопределенных уравнений может быть решено прямым методом после умножения его левой и правой частей на матрицу  $\mathbf{Q}_{i_0}^T$ , а именно:

$$\mathbf{Q}_{i_0}^T \mathbf{Q}_{i_0} \mathbf{f}_{i_0,l} = \mathbf{Q}_{i_0}^T \mathbf{q}_{i_0+1,l}.$$

Это уравнение дает решение, которое может рассматриваться как оптимальное, поскольку обеспечивает минимальную разность между левой и правой частями исходного переопределенного уравнения в евклидовой метрике. Таким образом, используя избыточную информацию, определяется вся идентифицируемая матрица.



Собственные значения идентифицируемой матричной функции  $\mathbf{F}_t$  являются функциями дискретного времени, представляя заданное ей преобразование. В общем случае, эти собственные значения являются комплексными, а соответствующие им собственные вектора – неортогональными. При этом значения с ненулевой мнимой частью образуют пары комплексно сопряженных значений, соответствующие преобразованиям в определенном двумерном инвариантном пространстве. Размерность задачи может быть понижена, если рассматривать динамику нескольких первых собственных значений, наибольших по абсолютной величине.

Траектории этих собственных значений на комплексной плоскости используются для попарных сравнений различных фрагментов полётов с целью распознавания их типов и выявления особенностей выполнения, включая аномальность. Для представления динамики каждого собственного значения используется свой марковский процесс с дискретными состояниями и дискретным временем (марковская цепь), при этом рассматриваемая область комплексной плоскости делится на ячейки конечной сеткой с достаточным разрешением, и  $j$ -му состоянию марковской цепи соответствует  $j$ -я ячейка этой сетки ( $j \in \{1, \dots, G\}$ ). Переходы между этими состояниями соответствуют переходам соответствующего собственного значения из одной ячейки в другую.

Выполнение  $s$ -го фрагмента полёта, где  $s \in \{1, \dots, S\}$ , представляется стохастической квадратной матрицей  $\mathbf{U}_s = (u_{ij,s})$  вероятностей переходов между состояниями марковской цепи, где  $u_{ij,s}$  – вероятность перехода из состояния  $j$  в состояние  $i$  ( $i, j \in \{1, \dots, G\}$ ). Динамика вероятностей пребывания в состояниях марковской цепи как функций дискретного времени определяется следующим матричным уравнением:

$$\mathbf{p}_{i+1} = \mathbf{U}_s \mathbf{p}_i,$$

где значения индекса  $i \in \{1, 2, \dots, N\}$  соответствуют дискретным моментам времени; вероятности пребывания в состояниях в момент времени  $i$  представляются как  $\mathbf{p}_i = (p_{i,1}, \dots, p_{i,G})^T$ . Каждый фрагмент полёта имеет свою собственную идентифицированную матрицу  $\mathbf{U}_s$  с уникальным набором вероятностей переходов между состояниями. Идентификация каждой матрицы  $\mathbf{U}_s$  выполняется, используя выборочные оценки частот переходов из одного состояния в другое, полученные для каждого рассматриваемого фрагмента полёта с помощью эмпирических данных.

Заданный  $s$ -й фрагмент полёта представляется последовательностью пройденных состояний  $\mathbf{V}_s = \{v_{1,s}, v_{2,s}, \dots, v_{N,s}\}$ . Правдоподобие фрагмента  $s_i$  по отношению к фрагменту  $s_j$  для  $j$ -й траектории собственных значений может быть представлено как условная вероятность  $P(\mathbf{V}_{e,s_i} | \mathbf{U}_{e,s_j})$ , которая вычисляется по последовательности пройденных состояний  $\mathbf{V}_{e,s_i} = \{v_{e,1,s_i}, v_{e,2,s_i}, \dots, v_{e,N,s_i}\}$  для матрицы  $\mathbf{U}_{e,s_j}$  вероятностей переходов:

$$P(\mathbf{V}_{e,s_i} | \mathbf{U}_{e,s_j}) = \prod_{k=1}^{N-1} u_{e, v_{k+1,s_i}, v_{k,s_i}, s_j}$$

Матрица  $\mathbf{Z}_e = (z_{e,ij})$ , где  $z_{e,ij} = -\ln P(\mathbf{V}_{e,s_i} | \mathbf{U}_{e,s_j})$  и  $i, j \in \{1, \dots, S\}$ , есть матрица взаимных расстояний для исследуемой выборки фрагментов полётов и  $j$ -й траектории собственного значения в метрике правдоподобия траекторий собственных



значений. Полная матрица взаимных расстояний фрагментов  $\mathbf{Z}$  определяется как сумма соответствующих частных матриц для каждой рассматриваемой траектории собственных значений:

$$\mathbf{Z} = \sum_e \mathbf{Z}_e.$$

Вследствие зависимости от последовательности пройденных состояний  $V_s$  марковской цепи, данный метод не очень чувствителен к разумным сдвигам во времени при синхронизации фрагментов полётов.

Основные элементы программной реализации рассмотренного подхода представлены в [11, 21].

### 4.3. Сравнение фрагментов полётов, используя метрику Кохонена в пространстве вейвлет-коэффициентов

Расчет значений метрики Кохонена в пространстве вейвлет-коэффициентов выполняется с помощью одной из разновидностей ассоциативных нейронных сетей – самоорганизующейся карты Кохонена (карты Кохонена). Каждому параметру действий экипажа требуется своя карта Кохонена. На входные слои этих структур подаются вейвлет-коэффициенты, представляющие параметры действий экипажей. Выходные слои (топологические карты) образуют прямоугольные матрицы, состоящие из элементов на радиальных базисных функциях (рис. 3). Для каждого элемента обучающей выборки определяется нейрон, ближайший к нему в евклидовой метрике («выигравший» нейрон). Затем, взяв взвешенную сумму прежнего центра «выигравшего» нейрона и соответствующего элемента обучающей выборки, параметры «выигравшего» нейрона и нейронов из его окрестности корректируются так, чтобы они в большей степени стали похожи на входной элемент, причем реализуемый «сдвиг» центров нейронов делается достаточно малым. В процессе обучения указанная окрестность сжимается до нуля. В результате последовательности таких коррекций определенные области топологической карты итерационно «сдвигаются» к определенным элементам обучающей выборки, при этом близкие входные данные обеспечивают «выигрыш» близко расположенных элементов топологических карт. Таким образом, самоорганизующиеся карты Кохонена учатся «понимать» структуру входных данных. Концепция этих карт построена на аналогии с ассоциативными свойствами человеческого мозга.

Взаимные расстояния между вейвлет-преобразованиями пар исследуемых процессов, представляющих различные действия экипажей, определяются как средние значения модулей двух следующих разностей:

- между расстоянием карты Кохонена от представления первого процесса до его «выигравшего» нейрона и расстоянием карты Кохонена от представления второго процесса до вычисленного «выигрышного» нейрона первого процесса, и, наоборот,
- между расстоянием карты Кохонена от представления второго процесса до его «выигравшего» нейрона и расстоянием карты Кохонена от представления первого процесса до вычисленного «выигрышного» нейрона второго процесса.

Общее взаимное расстояние является суммой соответствующих расстояний для всех параметров полётов. Поэтому, как и в случае евклидовой метрики в простран-



стве вейвлет-коэффициентов, могут быть вычислены оценки относительных вкладов параметров действий в элементы матриц взаимных расстояний.




Рис. 3. Входной и выходной слои самоорганизующейся карты Кохонена

Детальное описание процедуры вычисления расстояний в метрике Кохонена представлено в [21]. Пример, иллюстрирующий эффективность использования рассматриваемых метрик при сравнении фрагментов полетов разных типов, обсуждается в работе [11].

#### **4.4. Сравнение паттернов глазодвигательной активности, используя марковскую модель представления динамики перемещений взгляда, связанную с метрикой правдоподобия**

Сравнение динамики перемещений взгляда пилотов по зонам индикации опирается на оценки правдоподобия, количественно определяющие степень согласованности движений взгляда, измеренных при выполнении различных фрагментов полётов.

Для представления динамики перемещений взгляда по зонам индикации используются марковские процессы с дискретными состояниями и дискретным временем (цепи Маркова). В этих моделях зонам индикации соответствуют определённые состояния, образующие полную систему (т.е. данные состояния охватывают все допустимые области, куда может быть направлен взгляд). Пребывание в состоянии определяется нахождением взгляда в соответствующей ему зоне индикации. Такт дискретного времени – в зависимости от объёма накопленных эмпирических данных – либо задаётся определённым (и, как правило, небольшим) интервалом времени, либо соответствует интервалу времени, определяющему переход от одной фиксации взгляда к другой. Вероятности переходов между состояниями являются параметрами модели. Каждому исследуемому фрагменту полёта соответствует своя модель с уникальным набором вероятностей переходов между состояниями.



Перемещения взора характеризуются последовательностями пройденных зон индикации, которые в терминах данной модели интерпретируются как последовательности состояний.

Динамика вероятностей пребывания в состояниях модели как функций дискретного времени определяется следующим матричным уравнением:

$$p(t+1) = \mathbf{M}_1 p(t),$$

где  $t$  – дискретное время;  $0 \leq t \leq T$ ;  $t, T \in N$ ;  $T$  – конечный момент времени;  $N$  – множество натуральных чисел; вектор  $p(t) = (p_0(t), \dots, p_n(t))^T$  – представляет вероятности пребывания в состояниях модели в момент времени  $t$ ;  $n$  – число состояний марковского процесса;  $\mathbf{M}_1 = m_{ij,l}$  – стохастическая матрица вероятностей перехода между состояниями цепи Маркова порядка  $n$ , в которой  $m_{ij,l}$  – вероятность перехода из состояния  $j$  в состояние  $i$  для исследуемого фрагмента полёта  $l$ .

Идентификация рассмотренных марковских моделей для исследуемых фрагментов  $l \in \{0, \dots, z\}$  выполняется, используя экспериментальные данные о частотах переходов из одной зоны индикации в другую. Каждое исследуемый фрагмент  $l$  имеет свою идентифицированную матрицу  $\mathbf{M}_1$ .

Для вычисления вероятностей  $P(v_r | C_l)$  прохождения последовательности из  $r$  состояний марковского процесса при условии принадлежности к исследуемому фрагменту  $l$ , где  $C_l$  – факт принадлежности к исследуемому фрагменту  $l$ , а  $v_r$  – событие, представляющее собой прохождение последовательности из  $r$  состояний, используются элементы матриц  $\mathbf{M}_1$ :

$$P(v_r | C_l) = \prod_{k=1}^{r-1} m_{s_{k+1} s_k, l}$$

Величины  $\ln P(v_r | C_l)$  применяются в качестве оценок правдоподобия прохождения последовательности из  $r$  состояний при условии принадлежности к исследуемому фрагменту  $l$ . Использование оценок правдоподобия вместо соответствующих вероятностей при анализе динамики прохождения состояний модели обусловлено низкими порядками указанных вероятностей, которые неудобны для машинных вычислений.

Основные элементы программной реализации рассмотренного подхода представлены в [21].

## 5. ПРИМЕР: ВЫХОД ИЗ СЛОЖНОГО ПРОСТРАНСТВЕННОГО ПОЛОЖЕНИЯ

На рис. 5–11 представлена последовательность форм, иллюстрирующая этапы работы программно-аппаратного комплекса интеллектуальной поддержки и оценки уровня подготовки экипажа при выполнении выхода из сложного пространственного положения на универсальном стенде прототипирования кабины экипажа, разработанного ФГУП «ГосНИИАС». При сравнении фрагментов полётов использовалась евклидова метрика в пространстве вейвлет-коэффициентов. Итоговые оценки выполнения фрагмента полёта представлены на панели монитора (рис. 11).

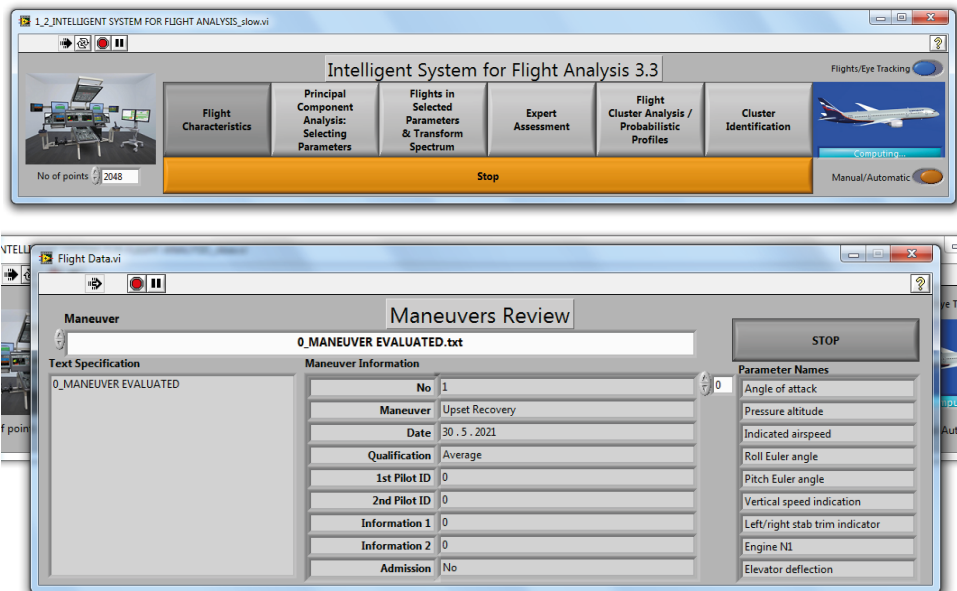


Рис. 5. The Intelligent System for Flight Analysis: информация о выбранном фрагменте полёта

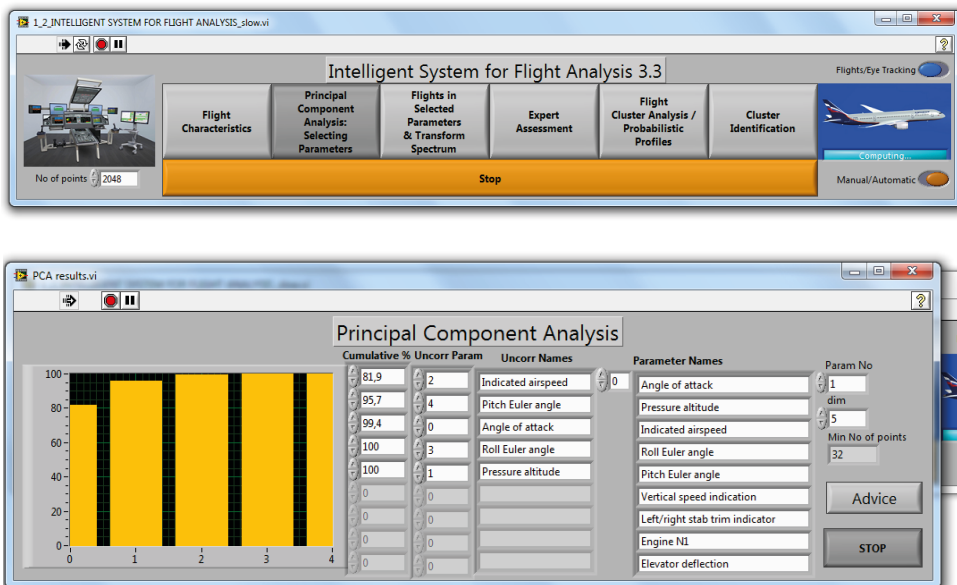


Рис. 6. The Intelligent System for Flight Analysis: выбор представителей групп параметров с высокой внутренней корреляцией с помощью метода главных компонент



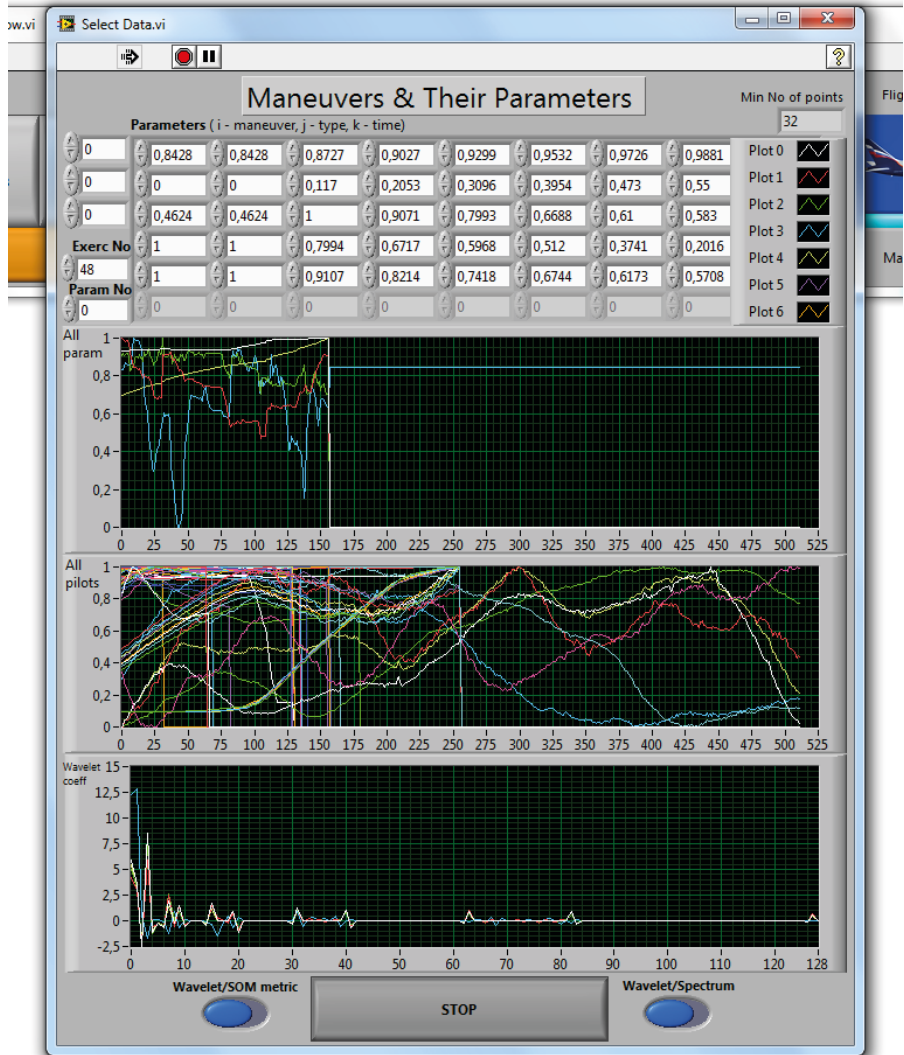



Рис. 7. The Intelligent System for Flight Analysis: представление временных рядов значений параметров соответствующими вейвлет-коэффициентами

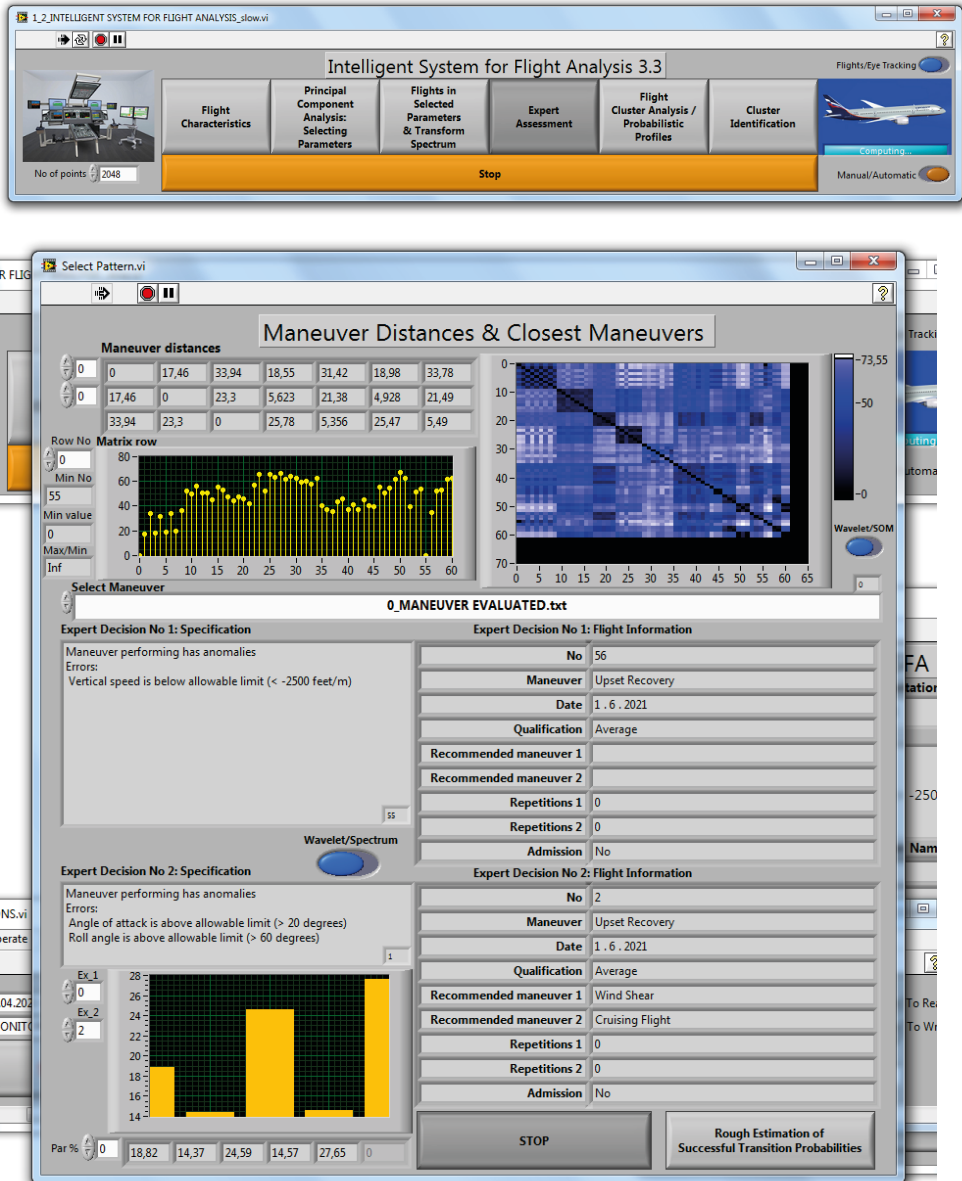


Рис. 8. The Intelligent System for Flight Analysis: расстояния от исследуемого фрагмента полёта до каждого паттерна из базы данных в заданной метрике; матрица взаимных расстояний между паттернами фрагментов полётов в цветовой шкале; информация о паттернах, ближайших к исследуемому; относительные вклады параметров полёта и состояния систем воздушного судна во взаимные расстояния между исследуемым и эталонным фрагментами полёта заданного типа





Рис. 9. The Intelligent System for Flight Analysis: паттерны различных типов фрагментов полётов в пространстве шкалирования; результаты их кластеризации, включая центры кластеров; вероятности принадлежности исследуемого фрагмента полёта к заданным кластерам фрагментов полётов разных типов, вычисленные в результате дискриминантного анализа.



1	Сложное пространственное положение
2	Посадка
3	Посадка с отказавшим двигателем
4	Взлёт
5	Уход на второй круг
6	Сдвиг ветра
7	Отказ двигателя после V1
8	Эшелон

Рис. 10. The Intelligent System for Flight Analysis: кластеризация фрагментов полётов в пространстве шкалирования (каждый кластер соответствует одному из заданных типов фрагментов полётов, указанных в таблице)

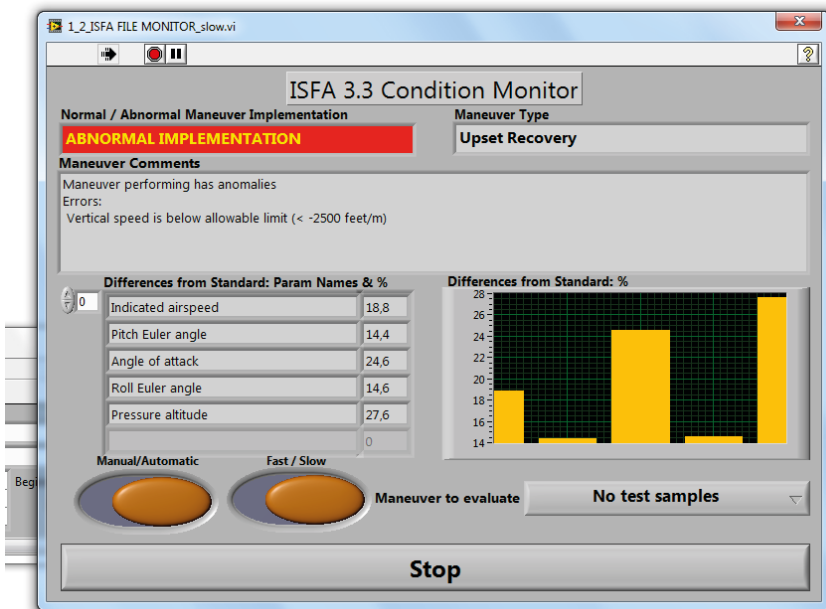


Рис. 11. The Intelligent System for Flight Analysis: оценка результатов пилотирования и состояния экипажа на панели монитора состояния полёта. На эту панель выводятся: сведения о нормальности или аномальности выполняемого фрагмента полёта, распознанный тип маневра, текстовое описание выявленной аномальности – если она имеет место – и процентный вклад наиболее значимых с точки зрения анализа лётных параметров, которыми обусловлены отличия оцениваемого фрагмента полёта от эталонного выполнения манёвра данного типа



## 6. ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ

1. Разработан новый подход к интеллектуальной поддержке лётных экипажей, основанный на сравнении текущих фрагментов полётов с паттернами, содержащимися в заранее сформированной специализированной базе данных и представляющими эмпирический интеллект системы.
2. Ключевым компонентом данного подхода являются четыре метрики, обеспечивающие значимую дискриминацию анализируемых фрагментов полётов и данных видеоокулографии различных типов и качества исполнения, а именно:
  - евклидова метрика в пространстве вейвлет-коэффициентов,
  - метрика правдоподобия траекторий собственных значений преобразований параметров деятельности,
  - метрика Кохонена в пространстве вейвлет-коэффициентов (с использованием ассоциативных нейронных сетей) и
  - метрика правдоподобия для сравнения траекторий движения взора.
3. Оценка уровня подготовки и состояния экипажа, а также элементы его интеллектуальной поддержки предполагают применение следующих математических методов:
  - метода понижения размерности задачи и определения представителей групп параметров с высокой внутренней корреляцией, построенного на базе метода главных компонентов;
  - многомерного шкалирования как метода разделения в пространстве шкалирования паттернов различных типов фрагментов полётов и глазодвигательной активности пилотов, а также нормальных/аномальных результатов деятельности;
  - кластерного анализа как метода разделения различных типов и уровней качества выполнения фрагментов полётов;
  - дискриминантного анализа как метода решения задачи классификации фрагментов полётов.
4. Разработанный подход продемонстрировал способность к распознаванию аномально выполненных фрагментов полетов и определению параметров, характеризующих ошибки пилота, обеспечивая таким образом последующее выявление их причин.
5. Рассмотренные результаты являются существенным шагом в развитии средств прогнозирования рисков и выявления факторов, способствующих возникновению опасных лётных ситуаций, в том числе в режиме реального времени, и могут применяться:
  - для оценки работы экипажей, включая контроль качества их обучения,
  - поддержки формирования инструкторских оценок,
  - обеспечения современных форм адаптивного обучения экипажей,
  - сравнения различных форматов системы экранной индикации в кабине экипажа,
  - оптимизации компоновки индикаторов кабины экипажа воздушного судна с учетом данных видеоокулографии,



- оценки влияния компоновки индикаторов кабины экипажа воздушного судна и условий полёта на риски возникновения авиационных инцидентов,
- сравнения различных средств и программ обучения лётного состава, а также при проектировании современных летательных аппаратов.

### *Литература*

1. Aircraft trajectory clustering techniques using circular statistics. Yellowstone Conference Center, Big Sky, Montana, 2016. IEEE.
2. Bastani V., Marcenaro L., Regazzoni C. Unsupervised trajectory pattern classification using hierarchical Dirichlet Process Mixture hidden Markov model // 2014 IEEE International Workshop on Machine Learning for Signal Processing (MLSP) / IEEE. 2014. Pp. 1–6.
3. Eerland W.J., Box S. Trajectory Clustering, Modelling and Selection with the focus on Airspace Protection // AIAA Infotech@ Aerospace. AIAA, 2016. Pp. 1–14.
4. Enriquez M. Identifying temporally persistent flows in the terminal airspace via spectral clustering // Tenth USA/Europe Air Traffic Management Research and Development Seminar (ATM2013) / Federal Aviation Administration (FAA) and EUROCONTROL. Chicago, IL, USA: 2013. June 10–13.
5. Enriquez M., Kurcz C. A Simple and Robust Flow Detection Algorithm Based on Spectral Clustering // International Conference on Research in Air Transportation (ICRAT) / Federal Aviation Administration (FAA) and EUROCONTROL. – Berkeley, CA, USA: 2012. May 22–25.
6. Faure C., Bardet J.M., Olteanu M., Lacaille J. Using Self-Organizing Maps for Clustering and Labelling Aircraft Engine Data Phases. In: WSOM (2017): 96–103.
7. Gaffney S., Smyth P. Joint probabilistic curve clustering and alignment // In Advances in Neural Information Processing Systems. Vol. 17. Cambridge, MA: MIT Press, 2005. Pp. 473–480.
8. Gaffney S., Smyth P. Trajectory clustering with mixtures of regression models // Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining. 1999. Pp. 63–72.
9. Gariel M., Srivastava A., Feron E. Trajectory clustering and an application to airspace monitoring // IEEE Transactions on Intelligent Transportation Systems. 2011. Vol. 12, no. 4. Pp. 1511–1524.
10. Grevtsov N. Synthesis of control algorithms for aircraft trajectories in time optimal climb and descent // Journal of Computer and Systems Sciences International. 2008. Vol. 47, no. 1. Pp. 129–138.
11. Kuravsky L.S. and Yuryev G.A. A novel approach for recognizing abnormal activities of operators of complex technical systems: three non-standard metrics for comparing performance patterns, International Journal of Advanced Research in Engineering and Technology (IJARET), 11(4), 2020, pp. 119–136. <http://www.iaeme.com/IJARET/issues.asp?JType=IJARET&VType=11&IType=4>
12. Kuravsky L.S., Yuryev G.A. Detecting Abnormal Activities of Operators of Complex Technical Systems and their Causes Basing on Wavelet Representations, International Journal of Civil Engineering and Technology (IJCIET) 10(2), 2019, pp. 724–742. <http://www.iaeme.com/IJCIET/issues.asp?JType=IJCIET&VType=10&IType=2>.
13. Kuravsky L.S., Yuryev G.A., Zlatomrezhev V.I. New approaches for assessing the activities of operators of complex technical systems. Eksperimental'naya psikhologiya = Experimental psychology (Russia), 2019, vol. 12, no. 4, pp. 27–49. doi:10.17759/exppsy.2019120403.
14. Kuravsky L.S., Yuryev G.A., Zlatomrezhev V.I., Yuryeva N.E. Assessing the Aircraft Crew Actions with the Aid of a Human Factor Risk Model. Eksperimental'naya psikhologiya = Experimental Psychology (Russia), 2020. Vol. 13, no. 2, pp. 153–181. DOI: <https://doi.org/10.17759/exppsy.2020130211>.



15. *Laxhammar R., Falkman G.* Online learning and sequential anomaly detection in trajectories // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2014. Vol. 36, no. 6. Pp. 1158–1173.
16. *Li Z., et al.* Incremental clustering for trajectories // *Database Systems for Advanced Applications. Lecture Notes in Computer Science*. 2010. Vol. 5982. Pp. 32–46.
17. *Liu H., Li J.* Unsupervised multi-target trajectory detection, learning and analysis in complicated environments // *2012 21st International Conference on Pattern Recognition (ICPR) / IEEE*. 2012. Pp. 3716–3720.
18. *Rintoul M., Wilson A.* Trajectory analysis via a geometric feature space approach // *Statistical Analysis and Data Mining: The ASA Data Science Journal*. 2015.
19. *Wei J., et al.* Design and Evaluation of a Dynamic Sectorization Algorithm for Terminal Airspace // *Journal of Guidance, Control, and Dynamics*. 2014. Vol. 37, no. 5. Pp. 1539–1555.
20. *Wilson A., Rintoul M., Valicka C.* Exploratory Trajectory Clustering with Distance Geometry // *International Conference on Augmented Cognition /Springer*. 2016. Pp. 263–274.
21. Отчёт о НИР «Разработка математических моделей и методов оценки уровня подготовки экипажа на основе анализа параметров полета, поступающих в процессе выполнения летных упражнений и данных видеоокулографии», ГосНИИАС, Москва, 2020.



## Principles of Developing a Software and Hardware Complex for Crew Intelligent Support and Training Level Assessment

**Ivan I. Greshnikov\***

State Research Institute of Aviation Systems (GosNIIAS), Moscow, Russia  
ORCID: <https://orcid.org/0000-0001-5474-3094>  
e-mail: [vvanes@mail.ru](mailto:vvanes@mail.ru)

**Lev S. Kuravsky\*\***

Moscow State University of Psychology and Education (MSUPE), Moscow, Russia  
ORCID: <http://orcid.org/0000-0002-3375-8446>  
e-mail: [l.s.kuravsky@gmail.com](mailto:l.s.kuravsky@gmail.com)

**Grigory A. Yuryev\*\*\***

Moscow State University of Psychology and Education (MSUPE), Moscow, Russia  
ORCID: <https://orcid.org/0000-0002-2960-6562>  
e-mail: [g.a.yuryev@gmail.com](mailto:g.a.yuryev@gmail.com)

Presented is a new approach to aircraft crew intelligent support, which is based on comparing flight fragments (maneuvers) under study with the relevant patterns contained in the database and representing the system “empirical intelligence”. Principal components of this approach are four new metrics for comparing flight fragments, viz.: the Euclidean metric in the space of wavelet coefficients; the likelihood metric of eigenvalue trajectories for transformations of activity parameters; the Kohonen metric in the space of wavelet coefficients; the likelihood metric for

### For citation:

Greshnikov I.I., Kuravsky L.S., Yuryev G.A. Principles of Developing a Software and Hardware Complex for Crew Intelligent Support and Training Level Assessment. *Modelirovanie i analiz dannykh = Modelling and Data Analysis*, 2021. Vol. 11, no. 2, pp. 5–30. DOI: <https://doi.org/10.17759/mda.2021110201> (In Russ., abstr. in Engl.).

\***Ivan I. Greshnikov**, Head of the Sector, State Research Institute of Aviation Systems (GosNIIAS), Moscow, Russia, ORCID: <https://orcid.org/0000-0001-5474-3094>, e-mail: [vvanes@mail.ru](mailto:vvanes@mail.ru)

\*\***Lev S. Kuravsky**, DSc (Engineering), Professor, Dean of the Computer Science Faculty, Head of the Department of Applied Informatics and Multimedia Technologies of the Faculty of Information Technologies, Moscow State University of Psychology and Education (MGPPU), Moscow, Russia, ORCID: <http://orcid.org/0000-0002-3375-8446>, e-mail: [l.s.kuravsky@gmail.com](mailto:l.s.kuravsky@gmail.com)

\*\*\***Grigory A. Yuryev**, PhD (Physical and Mathematical Sciences), Associate Professor, Professor of the Department of Applied Informatics and Multimedia Technologies, Deputy Dean of the Computer Science Faculty for Research, Head of the Laboratory for Mathematical Psychology and Applied Software of the Center of Information Technologies for Psychological Research, Moscow State University of Psychology and Education (MGPPU), Moscow, Russia, ORCID: <https://orcid.org/0000-0002-2960-6562>, e-mail: [g.a.yuryev@gmail.com](mailto:g.a.yuryev@gmail.com)





comparing gaze trajectories. Features of the presented approach are: the presence of an “intelligent component” that is contained in empirical data and can be flexibly changed as they accumulate; the use of integral comparisons of the flight fragments under study and video oculography data with relevant patterns of various types and performance quality from a specialized database, with transferring characteristics of the nearest pattern from this specialized database to the fragment under study; applying a complex combination of the methods for stochastic processes analysis and multivariate statistical techniques.

**Keywords:** operators of complex technical systems, intelligent crew support, crew training level assessment, video oculography, likelihood metric, Kohonen metric.

### **References**

1. Aircraft trajectory clustering techniques using circular statistics. Yellowstone Conference Center, Big Sky, Montana, 2016. IEEE.
2. Bastani V., Marcenaro L., Regazzoni C. Unsupervised trajectory pattern classification using hierarchical Dirichlet Process Mixture hidden Markov model // 2014 IEEE International Workshop on Machine Learning for Signal Processing (MLSP) / IEEE. 2014. Pp. 1–6.
3. Eerland W.J., Box S. Trajectory Clustering, Modelling and Selection with the focus on Airspace Protection // AIAA Infotech@ Aerospace. AIAA, 2016. Pp. 1–14.
4. Enriquez M. Identifying temporally persistent flows in the terminal airspace via spectral clustering // Tenth USA/Europe Air Traffic Management Research and Development Seminar (ATM2013) / Federal Aviation Administration (FAA) and EUROCONTROL. Chicago, IL, USA: 2013. June 10–13.
5. Enriquez M., Kurcz C. A Simple and Robust Flow Detection Algorithm Based on Spectral Clustering // International Conference on Research in Air Transportation (ICRAT) / Federal Aviation Administration (FAA) and EUROCONTROL. – Berkeley, CA, USA: 2012. May 22–25.
6. Faure C., Bardet J.M., Olteanu M., Lacaille J. Using Self-Organizing Maps for Clustering and Labelling Aircraft Engine Data Phases. In: WSOM (2017): 96–103.
7. Gaffney S., Smyth P. Joint probabilistic curve clustering and alignment // In Advances in Neural Information Processing Systems. Vol. 17. Cambridge, MA: MIT Press, 2005. Pp. 473–480.
8. Gaffney S., Smyth P. Trajectory clustering with mixtures of regression models // Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining. 1999. Pp. 63–72.
9. Gariel M., Srivastava A., Feron E. Trajectory clustering and an application to airspace monitoring // IEEE Transactions on Intelligent Transportation Systems. 2011. Vol. 12, no. 4. Pp. 1511–1524.
10. Grevtsov N. Synthesis of control algorithms for aircraft trajectories in time optimal climb and descent // Journal of Computer and Systems Sciences International. 2008. Vol. 47, no. 1. Pp. 129–138.
11. Kuravsky L.S. and Yuryev G.A. A novel approach for recognizing abnormal activities of operators of complex technical systems: three non-standard metrics for comparing performance patterns, International Journal of Advanced Research in Engineering and Technology (IJARET), 11(4), 2020, pp. 119–136. <http://www.iaeme.com/IJARET/issues.asp?JType=IJARET&V-Type=11&IType=4>
12. Kuravsky L.S., Yuryev G.A. Detecting Abnormal Activities of Operators of Complex Technical Systems and their Causes Basing on Wavelet Representations, International Journal of Civil Engineering and Technology (IJCIET) 10(2), 2019, pp. 724–742. <http://www.iaeme.com/IJCIET/issues.asp?JType=IJCIET&VType=10&IType=2>



13. Kuravsky L.S., Yuryev G.A., Zlatomrezhev V.I. New approaches for assessing the activities of operators of complex technical systems. *Eksperimental'naya psikhologiya = Experimental psychology (Russia)*, 2019, vol. 12, no. 4, pp. 27–49. doi:10.17759/expsy.2019120403.
14. Kuravsky L.S., Yuryev G.A., Zlatomrezhev V.I., Yuryeva N.E. Assessing the Aircraft Crew Actions with the Aid of a Human Factor Risk Model. *Eksperimental'naya psikhologiya = Experimental Psychology (Russia)*, 2020. Vol. 13, no. 2, pp. 153–181. DOI: <https://doi.org/10.17759/expsy.2020130211>.
15. Laxhammar R., Falkman G. Online learning and sequential anomaly detection in trajectories // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2014. Vol. 36, no. 6. Pp. 1158–1173.
16. Li Z., et al. Incremental clustering for trajectories // *Database Systems for Advanced Applications. Lecture Notes in Computer Science*. 2010. Vol. 5982. Pp. 32–46.
17. Liu H., Li J. Unsupervised multi-target trajectory detection, learning and analysis in complicated environments // 2012 21st International Conference on Pattern Recognition (ICPR) / IEEE. 2012. Pp. 3716–3720.
18. Rintoul M., Wilson A. Trajectory analysis via a geometric feature space approach // *Statistical Analysis and Data Mining: The ASA Data Science Journal*. 2015.
19. Wei J., et al. Design and Evaluation of a Dynamic Sectorization Algorithm for Terminal Airspace // *Journal of Guidance, Control, and Dynamics*. 2014. Vol. 37, no. 5. Pp. 1539–1555.
20. Wilson A., Rintoul M., Valicka C. Exploratory Trajectory Clustering with Distance Geometry // *International Conference on Augmented Cognition /Springer*. 2016. Pp. 263–274.
21. Research report “Development of mathematical models and methods for assessing the level of crew training based on the analysis of flight parameters received during flight exercises and video oculography data”, GosNIIAS, Moscow, 2020.