



# ОЦЕНКА ДЕЙСТВИЙ ЭКИПАЖА ВОЗДУШНОГО СУДНА НА ОСНОВЕ МОДЕЛИ РИСКОВ ЧЕЛОВЕЧЕСКОГО ФАКТОРА

## **КУРАВСКИЙ Л.С.**

*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 Г.А.**

*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)

## **ЗЛАТОМРЕЖЕВ В.И.**

*Государственный научно-исследовательский институт авиационных систем (ФГУП «ГосНИИАС»), г. Москва, Российская Федерация*  
ORCID: <https://orcid.org/0000-0003-1776-6881>, e-mail: [vizlatomr@2100.gosniias.ru](mailto:vizlatomr@2100.gosniias.ru)

## **ЮРЬЕВА Н.Е.**

*Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация*  
ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: [yurieva.ne@gmail.com](mailto:yurieva.ne@gmail.com)

В статье представлена модель рисков человеческого фактора при пилотировании воздушного судна. Эта модель построена на сравнениях представлений оцениваемых действий экипажей с сопоставимыми представлениями действий различных типов и качества исполнения, образующих репрезентативную выборку и содержащихся в заранее сформированной специализированной базе данных. Риск представляется вероятностными оценками, которые строятся в результате последовательного применения метода главных компонент, многомерного шкалирования и кластерного анализа к трем типам характеристик: параметрам полета и состояния систем воздушного судна, траекториям движения глаз и временным рядам первичных показателей глазодвигательной активности, — что приводит к формированию кластеров фрагментов полетов различных типов и качества исполнения, включая аномальные. Дискриминантный анализ обеспечивает вычисление вероятностного профиля принадлежности к целевым кластерам, на основе которого строится итоговое заключение. Ключевым элементом представленного подхода являются три новые метрики, применяемые для сравнений действий экипажей и обеспечивающие значимую дискриминацию фрагментов полетов различных типов и качества исполнения. Выполняется детализация вкладов параметров полета и состояния систем воздушного судна в различия фрагментов полетов в заданной метрике, результаты которой используются при содержательном анализе причин выявляемой аномальности. При достаточной скорости вычислений рассмотренный анализ полетных данных в автоматическом режиме может быть выполнен в реальном времени.

**Ключевые слова:** модель рисков человеческого фактора, метод главных компонент, многомерное шкалирование, кластерный анализ, показатели глазодвигательной активности.

---

**Благодарности:** Эта работа выполнена как часть проекта «SAFEMODE» (грант № 814961) при финансовой поддержке Министерства науки и высшего образования Российской Федерации (проект UID RFMEFI62819X0014).



Для цитаты: Куравский Л.С., Юрьев Г.А., Златомрежев В.И., Юрьева Н.Е. Оценка действий экипажа воздушного судна на основе модели рисков человеческого фактора // Экспериментальная психология. 2020. Том 13. № 2. С. 153–181. DOI: <https://doi.org/10.17759/exppsy.2020130211>

## ASSESSING THE AIRCRAFT CREW ACTIONS WITH THE AID OF A HUMAN FACTOR RISK MODEL

**LEV S. KURAVSKY**

*Moscow State University of Psychology and Education, 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, Moscow, Russia,*

ORCID: <https://orcid.org/0000-0002-2960-6562>, e-mail: [g.a.yuryev@gmail.com](mailto:g.a.yuryev@gmail.com)

**VALENTINI. ZLATOMREZHEV**

*State Research Institute of Aviation Systems (GosNIIAS), Moscow, Russia,*

ORCID: <https://orcid.org/0000-0003-1776-6881>, e-mail: [vizlatomr@2100.gosniias.ru](mailto:vizlatomr@2100.gosniias.ru)

**NATALIYA E. YURIEVA**

*Moscow State University of Psychology and Education, Moscow, Russia,*

ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: [yurieva.ne@gmail.com](mailto:yurieva.ne@gmail.com)

Presented is a human factor risk model when piloting an aircraft. This model is based on comparing representations of the evaluated crew actions with the comparable action representations of various types and performance quality, which form a representative sample and are contained in a pre-formed specialized database. The risk in question is represented by probabilistic estimates, which result from consistent applications of the Principal Component Analysis, Multidimensional Scaling, and Cluster Analysis to three types of characteristics, viz.: parameters of flights and states of aircraft systems, gaze movement trajectories and time series of oculomotor activity primary indexes. These steps form the clusters of flight fragments for various types and performance quality, including abnormal ones. The Discriminant Analysis provides calculating the probabilistic profile for belonging to certain target clusters, with a final conclusion being derived from this structure. Key elements of the approach presented are three new metrics used to compare crew actions and to ensure significant discrimination for flight fragments of various types and performance quality. Detailing flight parameters contributions in differences of the flight fragments in a given metric is carried out to provide meaningful analysis of the detected abnormality causes. With sufficient computational performance, the flight data analysis under consideration can be implemented in real time automatic mode.

**Keywords:** human factor risk model, Principal Component Analysis, Multidimensional Scaling, Cluster Analysis, oculomotor activity indexes.

---

**Acknowledgements:** This work was performed as a part of the “SAFEMODE” Project (Grant Agreement No 814961) with the financial support of the Ministry of Science and Higher Education of the Russian Federation (Project UID RFMEF162819X0014).

**For citation:** 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> (In Russ.).



## Введение

Объективная оценка эффективности работы пилотов важна для оценки рисков, связанных с информационно-управляющим полем (ИУП) кабины экипажа воздушного судна, оптимизации ИУП и обучения экипажей. Одной из критических проблем при этом является разработка критериев оценки. Данные, основанные на характеристиках действий экипажей, могут быть использованы для объективной оценки эффективности обучения и навыков, приобретенных в его результате. Таким образом, актуальна разработка методов компьютеризированной диагностики, которые можно применять в ходе подбора летного состава для оценки уровня полученных знаний, способностей и навыков. Эти методы помогут улучшить объективность, информативность и точность оценок, а также обеспечить стандартизацию и автоматизацию измерений. Особое значение имеют разработка и анализ новых подходов, которые могут применяться для оценки уровня обучения и психофизиологического состояния пилотов. При этом основным направлением является диагностика по результатам работы на современных *тренажерах и стендах*, где возможно воспроизведение особых условий работы пилотов.

Под *риском* понимается мера количества опасности, измеряемой в форме экспертного значения сочетания двух величин — нормированной частоты или меры возможности случайного появления опасных событий и возможного обобщенного ущерба от этих событий [14]. Классический подход к количественной оценке рисков пилотирования основывается на оценке вероятности ошибок экипажа, значение которой изменяется в зависимости от различных условий и обстоятельств.

Анализ концепций и технологий, используемых на сегодняшний день для снижения рисков и тяжести последствий авиационных инцидентов, показывает существенный интерес профессионального сообщества к различным аспектам проблемы безопасности полетов. С усложнением авиационной техники и ростом числа перелетов становится возможным формирование концепций предотвращения инцидентов, построенных на базе математических моделей с использованием детализированной информации как о параметрах пилотирования воздушных судов, так и о состоянии пилотов, диспетчеров и других членов экипажа.

Важно отметить, что подходы к оценке рисков, требующие использования многочисленных и трудно идентифицируемых параметров летательных аппаратов и их систем, не имеют перспектив практического применения, поскольку погрешности оценки указанных параметров, а также, как правило, неопределенная степень чувствительности результата оценки к варьированию этих параметров делают данные подходы предельно ненадежными. Вопросы структурной устойчивости моделей оценки рисков обычно даже не рассматриваются.

Большие проблемы на практике создают расчетные модели, требующие детализации оценки рисков по подсистемам летательного аппарата. Поскольку при решении задачи необходимо рассматривать большое количество взаимодействующих систем, это приводит к перебору многочисленных вариантов поведения сложной технической системы, что непременно усложняет анализ.

Подходы, опирающиеся на статистический анализ больших выборок, включая данные о выходе из строя отдельных систем, позволяют выявлять тенденции, но не дают возможности делать определенный прогноз в конкретной практической ситуации, что существенно ограничивает возможности применения.

Кроме того, переход от одного типа летательного аппарата к другому требует для большинства рассмотренных подходов практически полной переделки всей расчетной модели.



К сожалению, практически все разработанные ранее методы имеют один и более из перечисленных недостатков.

Если исходить из критериев простоты практического применения, отсутствия привязки расчетной модели к конкретному типу летательного аппарата (универсальности) и отсутствия необходимости детально исследовать трудоемкие проблемы чувствительности и структурной устойчивости расчетных моделей, то модели оценки рисков пилотирования целесообразно строить на непосредственном анализе измеряемых параметров полета и интегральных оценках фрагментов полетов в целом, без детализации по параметрам (недостатки такой детализации рассмотрены в последующем разделе), а также данных видеодокументации, позволяющих надежно оценивать влияние ИУП кабины экипажа на эффективность пилотирования. Один из вариантов такого подхода рассмотрен в этой работе.

К настоящему времени получено определенное количество результатов, связанных с выявлением аномально выполненных летных упражнений [1; 2; 5; 7–13; 15–16; 31–33; 37; 39, 40]. В подавляющем большинстве случаев рассматриваются только параметры траектории воздушного судна. Существенные ограничения, ограничивающие применение указанных результатов на практике, рассмотрены в [28-30]. Следует отметить, что одним из основных недостатков является применение традиционных метрик для сравнения фрагментов полетов, поскольку эти метрики не обеспечили решение исследуемой и связанных с ней задач.

*В связи с тем, что один из наиболее популярных, но наименее эффективных простых методов оценки качества пилотирования заключается в проверке того, находятся ли определенные параметры в заданных пределах критических значений для указанных режимов полета, неизбежны комментарии на эту тему. Валидность такого подхода лучше всего пояснить с помощью следующей аналогии: он выглядит, как попытка оценить качество вождения автомобиля количеством столкновений с забором вдоль дороги, игнорируя при этом всю остальную информацию о движении автомобиля. Очевидно, что эффективность и уместность таких оценок не выдерживает критики.*

Существующие проблемы преодолеваются с помощью методов [28-30]. Далее представлены способы оценки навыков с использованием полученных экспериментально релевантных данных о пилотировании. В результате их применения определяются классы навыков с использованием параметров полетов, выявляемых в процессе выполнения упражнений. Под *параметрами полетов* далее понимаются измеряемые характеристики, определяющие движение и состояние систем летательного аппарата.

Чтобы анализировать данные о пилотировании, необходима специализированная база данных, в которой собраны *паттерны* их деятельности, характеризующие выполнение упражнений пилотами с различным уровнем подготовки. Под *паттерном* понимается представление определенного фрагмента анализируемой деятельности, называемого *упражнением*, с помощью набора релевантных параметров. Эти паттерны соотносятся с одним из распознаваемых уровней сформированности навыков.

Собранные в базе данные должны включать в себя параметры выполнения упражнений, а также соответствующие комментарии, содержащие экспертные оценки из различных источников, включая различные типы тренажеров и стендов, системы виртуальной реальности, а также результаты реальной работы. Комментарии экспертов должны выявлять слабые стороны работы экипажей, охватывая информацию о типичных ошибках в терминах параметров деятельности и советы инструктору о том, как исправить указанные недостатки.



*Общее допущение для рассматриваемых подходов заключается в том, что действия, выполняемые разными стилями и с разным качеством, а также упражнения разных типов отделяются друг от друга в многомерном пространстве, сформированном в метриках вейвлет-представлений различных вариантов работы экипажей или в метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности. Это утверждение обосновывается результатами вычислительных экспериментов, использующих релевантные эмпирические данные. Общий метод, вытекающий из этого заключения, опирается на выбор паттернов.*

*Данные подходы могут быть использованы для поддержки процесса обучения пилотов, формирования инструкторских оценок, а также для обеспечения автоматической оценки качества пилотирования в режиме реального времени. Эти средства анализа существенно отличаются от вероятностных методов, применяемых при управлении системами, прогнозировании технических неисправностей, мониторинге состояния и поддержке управляющих действий пилотов [18].*

### **Оценка рисков человеческого фактора при пилотировании воздушного судна**

Поскольку под риском понимается мера количества опасности, то *модель рисков* человеческого фактора при пилотировании воздушного судна (ВС) фактически представляет собой модель *оценки рисков*. Разработанная модель оценки рисков человеческого фактора, связанных с ИУП кабины экипажа воздушного судна, представлена на рис. 1. Эта модель построена на сравнениях представлений оцениваемых действий экипажей с сопоставимыми представлениями действий различных типов и качества исполнения, образующих репрезентативную выборку и содержащихся в заранее сформированной специализированной базе данных.

Риск представляется вероятностными оценками, которые строятся в результате последовательного применения *метода главных компонентов, многомерного шкалирования и кластерного анализа* к трем типам характеристик:

- параметрам полета и состояния систем воздушного судна;
- траекториям движения глаз;
- временным рядам первичных показателей глазодвигательной активности (ГДА),

что приводит к формированию кластеров фрагментов полетов различных типов и качества исполнения, включая аномальные.

*Обобщенный дискриминантный анализ* обеспечивает вычисление вероятностного профиля принадлежности к целевым кластерам, на основе которого строится итоговое заключение.

*Ключевым элементом используемого подхода являются три новые метрики, обеспечивающие значимую дискриминацию фрагментов полетов различных типов и качества исполнения, а именно: евклидова метрика и метрика Кохонена для вейвлет-представлений различных вариантов работы экипажей, а также метрика правдоподобия траекторий собственных значений для преобразований параметров деятельности, — без применения которых многомерное шкалирование и кластерный анализ не дали бы желаемый результат.*

Выполняется детализация вкладов параметров полета и состояния систем воздушного судна в различия фрагментов полетов в заданной метрике, результаты которой используются при содержательном анализе причин выявляемой аномальности.

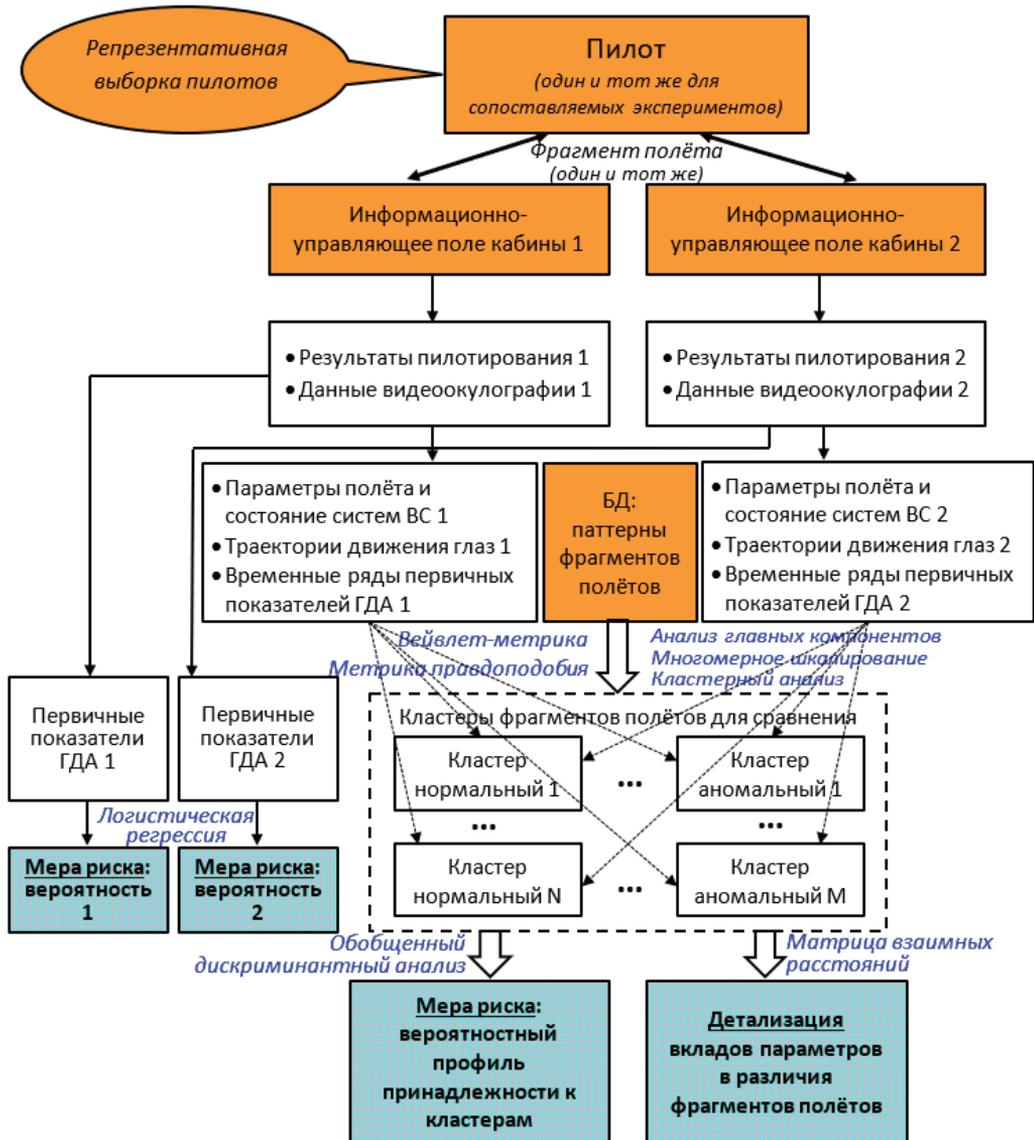


Рис. 1. Модель оценки рисков человеческого фактора, связанных с ИУП кабины экипажа воздушного судна, при пилотировании воздушного судна

В качестве упрощенного альтернативного подхода, вероятность риска также может оцениваться по первичным показателям ГДА, используя логистическую регрессию.

### **Анализ параметров деятельности экипажа, представленных с помощью дискретных вейвлет-преобразований их временных рядов**

Полагается, что работа экипажа представлена набором временных рядов, описывающих динамику параметров технической системы, а также, если возможно, состояние пилотов. Основные этапы рассматриваемого анализа и их взаимные связи приведены на рис. 2.



Можно выделить следующие цели данного анализа:

- обеспечение оценки результатов текущей деятельности путем ее сравнения с паттернами, предварительно собранными в соответствующей базе данных;
- распознавание аномальной деятельности и выявление параметров, характеризующих ошибки пилота, с целью определения источников аномальности.

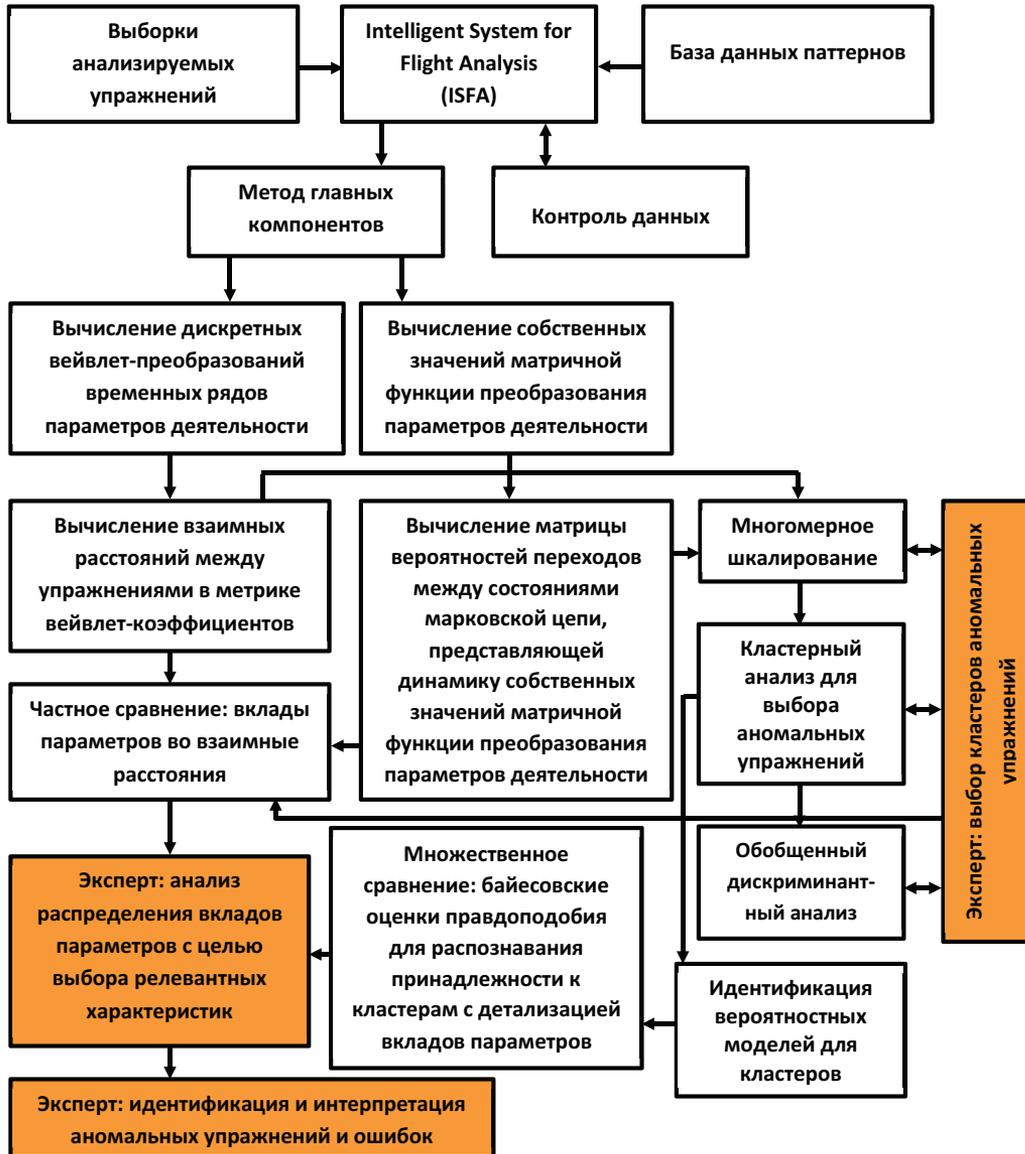


Рис. 2. Основные этапы анализа и связи между ними (действия экспертов выделены цветом)

На этапе предварительной обработки выбираются временные интервалы для сравнения упражнений и проводится нормализация данных.

Избыточная информация исключается с помощью *метода главных компонентов* [36; 41]. Для этого рассчитываются матрицы взаимных корреляций временных рядов, реша-



ется алгебраическая задача собственных значений и определяется, до какой степени можно уменьшить размерность собственного подпространства исследуемых параметров, так чтобы оно содержало достаточно представительную часть изменчивости наблюдаемых параметров. По каждому из выбранных собственных направлений этого подпространства (главному компоненту) по одной из самых высоких компонентных нагрузок выбирается представитель из числа регистрируемых параметров (*переход в базис главных компонент нецелесообразен из-за неопределенности содержательной интерпретации главных компонент и — в ряде прикладных задач — из-за отсутствия точной синхронизации исследуемых процессов для различных упражнений во времени*). Цель этого этапа — выявить относительно независимые характеристики, заменяющие группы существенно коррелирующих параметров лишь одним характерным представителем, чтобы избежать на последующих этапах искажений, обусловленных комбинированным воздействием сильно зависимых характеристик.

Временные ряды, характеризующие исследуемые процессы, заменяются на ряды вейвлет-коэффициентов, полученных в результате *кратномасштабного анализа* [35]. 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 упражнениям одного типа, поскольку наиболее значимые коэффициенты, относящиеся к более продолжительным временным интервалам, практически нечувствительны к умеренным сдвигам во времени.*

Для исследуемых упражнений далее следует либо вычислить матрицу взаимных расстояний между вейвлет-представлениями различных вариантов работы экипажей в евклидовой метрике и метрике Кохонена, либо применить подход, при котором в метрике правдоподобия траекторий собственных значений рассчитываются аналогичные матрицы, связанные с наблюдаемыми фрагментами деятельности. Матрицы взаимных расстояний, вычисленные для всех рассматриваемых параметров, складываются, в результате чего получается общая матрица взаимных расстояний между исследуемыми упражнениями. При анализе аномально выполненных упражнений вычисляются относительные вклады параметров деятельности в элементы матриц взаимных расстояний, что позволяет определить параметры, характеризующие ошибки пилота, с целью выявления причин аномальности.

Для анализа взаимного расположения упражнений в пространстве приемлемой размерности, после расчета матрицы взаимных расстояний выполняется *многомерное шкалирование* [3,38]. Вычисленное распределение анализируемых упражнений в построенном пространстве многомерного шкалирования далее используется для определения расстояний между упражнениями при формировании диагностических выводов. Размерность пространства шкалирования определяется по критерию достаточной дифференциации выборов упражнений, относящихся к различным распознаваемым классам. Выполнение этого этапа обеспечивает последующее разделение в пространстве шкалирования упражнений различных типов и нормальных/аномальных результатов деятельности.



Для выявления кластеров, представляющих различные типы упражнений и классы навыков пилотов, в полученном пространстве шкалирования для паттернов выполняется *кластерный анализ*. Полученные результаты позволяют создать классификационные правила для разделения различных уровней качества выполнения упражнений, а также их типов в пространстве шкалирования; при этом различия между кластерами различных вариантов выполнения одних и тех же упражнений объясняются тем, что их реализация обусловлена индивидуальными навыками.

Для описания вероятностной динамики каждого класса навыков пилотов с целью прогнозирования его поведения, для каждого кластера паттернов, применяя процедуру идентификации, создаются вероятностные модели, представленные марковскими случайными процессами с дискретными состояниями и непрерывным временем [6; 19–26; 34].

Вычисление расстояний до центров кластеров паттернов или до ближайших паттернов основываются на результатах выполнения последовательности контрольных упражнений. Если объем выборок паттернов достаточно велик, расстояния определяются до центров кластеров паттернов, определённых, опираясь на полученные ранее данные многомерного шкалирования. Если выборки паттернов небольшие, то определяется ближайший паттерн, который можно найти двумя способами: или непосредственно путем вычисления паттерна, ближайшего в метрике вейвлет-представлений, или путем определения ближайшего паттерна в полученном пространстве шкалирования.

Доступны три способа определения класса навыков:

— прямое сравнение анализируемых упражнений с паттернами деятельности из базы данных в метрике вейвлет-представлений, связанной с наблюдаемыми упражнениями (этот способ рассматривается как основной), а также

— вероятностные оценки распознавания класса навыков с помощью обобщенного дискриминантного анализа, используя выборочные функции распределения расстояний упражнений до центров кластеров в пространстве шкалирования (этот способ рассматривается как вспомогательный), и

— байесовские оценки правдоподобия (выбор класса навыков с помощью вероятностного профиля пребывания в диапазонах параметров деятельности — этот способ также рассматривается как вспомогательный).

При этом эксперт отвечает за:

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

Необходимые вычисления обеспечивает *Intelligent System for Flight Analysis (ISFA)* [27] — система, в которой разработанные методы реализованы в среде графического программирования *LabVIEW* [4].

Евклидова метрика вейвлет-представлений различных вариантов работы экипажей и метрика правдоподобия траекторий собственных значений для преобразований параметров деятельности детально рассмотрены в [28-30]. Описание метрики Кохонена, разработанной после публикации этих работ, представлено в следующем разделе.

Пример практического применения рассматриваемого подхода, демонстрирующий автоматическую оценку рисков пилотирования в режиме реального времени, представлен в Приложении.



## Метрика Кохонена в пространстве вейвлет-коэффициентов

Расчет значений метрики Кохонена в пространстве вейвлет-коэффициентов выполняется с помощью *самоорганизующихся карт признаков Кохонена (карт Кохонена)* [10; 17]. 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.

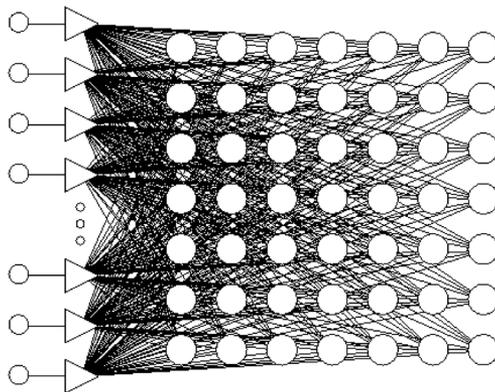


Рис. 3. Входной и выходной слои самоорганизующейся карты Кохонена

Взаимные расстояния между вейвлет-преобразованиями пар исследуемых процессов, представляющих различные действия экипажей, определяются как средние значения 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 действий экипажей. 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.

Пример, иллюстрирующий эффективность использования трех рассматриваемых метрик при сравнении фрагментов полетов разных типов, обсуждается в следующем разделе.

### Сравнение рассматриваемых метрик на примере прикладной задачи

Чтобы проиллюстрировать эффективность применения трех рассматриваемых метрик, ниже представлен анализ 34 летных упражнений пяти типов: «восстановление из сложного пространственного положения», «сдвиг ветра», «заход на посадку с одним двигателем», «отказ двигателя при взлете» и «полет по кругу», — выполненных на универсальном стенде прототипирования Государственного НИИ авиационных систем (ГосНИИАС) (рис. 4). Матрицы взаимных расстояний, вычисленные с помощью евклидовой метрики и метрики Кохонена в пространстве вейвлет-коэффициентов, показывают хорошо выраженные различия между упражнениями разных типов (рис. 5 а, с). Эта же матрица, вычисленная в метрике правдоподобия, также показывает эти различия, однако они не столь явно выражены (рис. 5 б).



Рис. 4. Универсальный стенд прототипирования кабины экипажа Государственного НИИ авиационных систем

Диаграммы рассеяния летных упражнений, полученные в результате многомерного шкалирования, представлены на рис. 6. Для количественной оценки качества дискриминации между рассматриваемыми типами упражнений может быть использована *статистика Уилкса (L-статистика)*. Ее значения лежат в интервале от 0 до 1, причем близкие к нулю значения свидетельствуют о хорошей дискриминации, а близкие к единице — об ее отсутствии. Поскольку описание распределения статистики Уилкса, которое доступно в настоящее время, не является достаточно точным и полным, для оценки значимости дискриминации используется хорошо изученное *F-отношение* (называемое в данном контексте *ассоциированной F-статистикой*). Значения статистики Уилкса при этом пересчитываются в значения F-статистики, которая используется для проверки гипотезы о совпадении центроидов исследуемых типов упражнений.

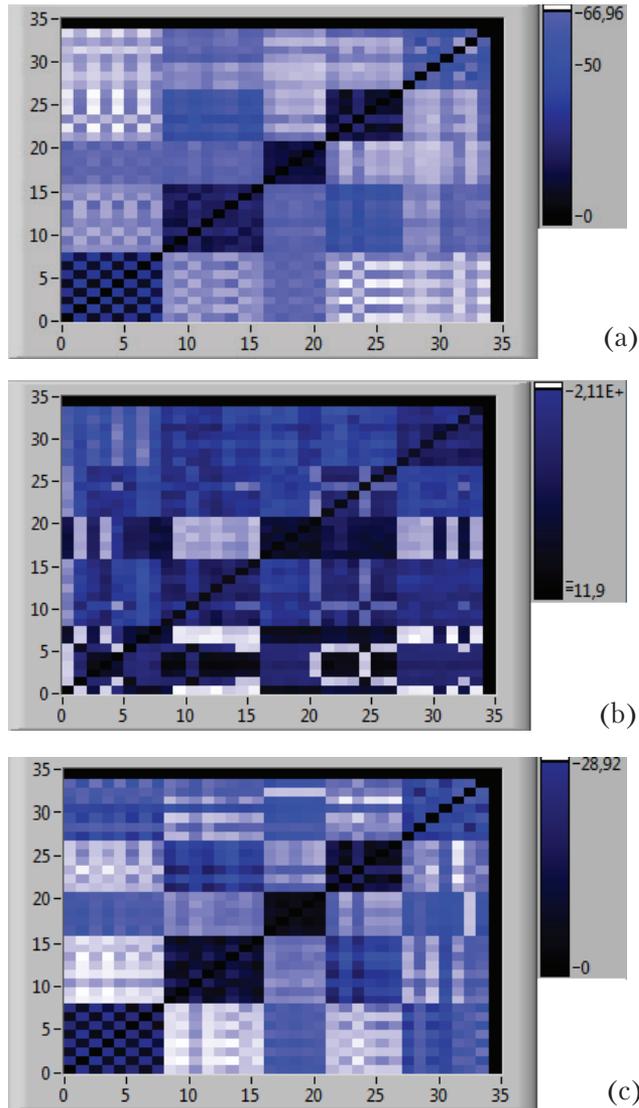


Рис. 5. Матрицы взаимных расстояний для 34 летных упражнений пяти типов, вычисленные с помощью: (а) евклидовой метрики в пространстве вейвлет-коэффициентов; (б) метрики правдоподобия; (с) метрики Кохонена в пространстве вейвлет-коэффициентов

Значения указанных статистик, показанные в табл. 1, подтверждают, что евклидова метрика и метрика Кохонена обеспечивают высокосignificant дискриминацию между упражнениями различных типов, в то время как метрика правдоподобия приводит к достаточно значимой дискриминации в целом. Линейный дискриминантный анализ Фишера показывает несколько меньшее количество неправильных решений в случае метрики Кохонена. В целом, несмотря на совершенно разные способы построения, евклидова метрика и метрика Кохонена в данной задаче дают примерно одинаковые результаты.

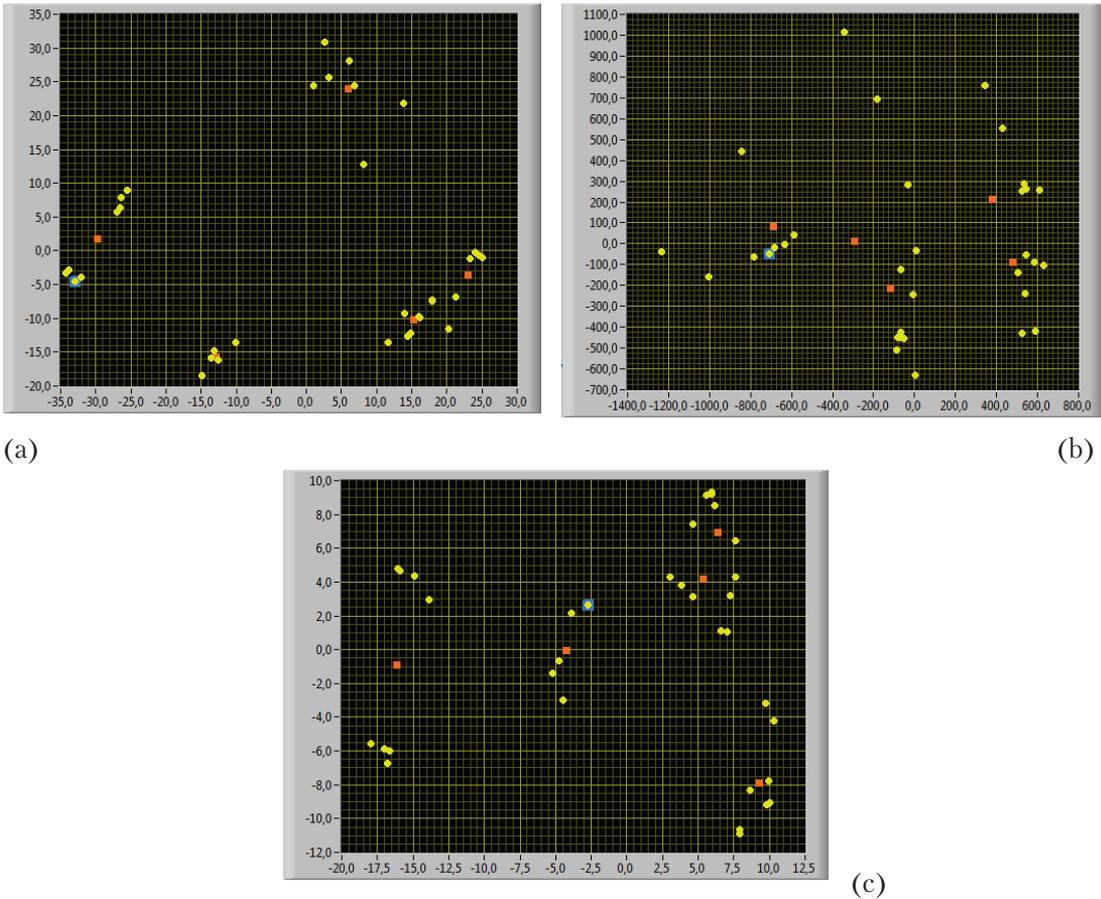


Рис. 6. Диаграммы рассеяния для 34 летных упражнений пяти типов, полученные в результате многомерного шкалирования в случае: (а) евклидовой метрики в пространстве вейвлет-коэффициентов; (b) метрики правдоподобия; (с) метрики Кохонена в пространстве вейвлет-коэффициентов

Таблица 1

**Оценка качества дискриминации для летных упражнений пяти типов в случае евклидовой метрики, метрики правдоподобия и метрики Кохонена: статистика Уилкса и ассоциированная F-статистика**

	Евклидова метрика в пространстве вейвлет-коэффициентов	Метрика правдоподобия	Метрика Кохонена в пространстве вейвлет-коэффициентов
Статистика Уилкса: 34 летные упражнения пяти типов	0,0015	0,34	0,0016
Ассоциированная F-статистика (F(8,56)): 34 летные упражнения пяти типов	174,5 ( $p < 0,0001$ )	5,07 ( $p < 0,0001$ )	170,2 ( $p < 0,0001$ )

Учитывая существенно различную природу построенных метрик, разумно не выбирать одну или две из них, а использовать их одновременно, сопоставляя полученные результаты.



## Упрощенный подход: оценка вероятности риска принятия неправильного решения по первичным показателям ГДА с помощью логистической регрессии

Оценка вероятности риска принятия неправильного решения однозначно (как дополнение до единицы) связана с вероятностью принятия правильного решения, приводящего к устранению критической ситуации. Оценка этого показателя выполняется в два этапа:

- идентифицируется зависимость этой вероятности от некоторого параметра, доступного для оценок по экспериментальным данным;
- проводятся измерения с целью оценок указанного параметра с помощью айтрекера.

В качестве такого параметра далее рассматривается *продолжительность принятия решения*.

Будем полагать, что  $R = t_{r0} + t$ , где  $R$  – продолжительность критической ситуации,  $t_{r0}$  – продолжительность считывания и обработки пилотом информации с индикаторов,  $t$  – продолжительность принятия решения.

Полагаем, что при достаточно большом времени для вероятности принять правильное решение адекватна модель Г. Раша [25], представленная логистической функцией (рис. 7):

$$p(\Delta) = \frac{e^{a\Delta}}{1 + e^{a\Delta}}$$

где  $\Delta = C(t) - D$ ;  $C(t)$  – способность принять правильное решение в *логитах*,  $D$  – трудность задания ситуации) в *логитах*,  $a$  – параметр (реальное эмпирическое значение равно 1,7).

Как способности принять правильное решение, так и трудности заданий (ситуаций) измеряются в единой безразмерной шкале *логитов*, выражающей соотношение долей правильных и неправильных действий при наблюдениях. Перевод в шкалу логитов осуществляется по формуле:

$$L = \ln \frac{r}{1 - r}$$

где  $L$  – значение в шкале логитов,  $r$  – вероятность правильного выполнения задания. В случае оценки трудности этот параметр характеризует возможность выполнения определенного задания для всего множества субъектов, а в случае оценки способностей – результаты определенного субъекта для всего множества допустимых заданий. Статистические приближения указанных величин получают после замены в приведенной формуле вероятности  $r$  на ее выборочные оценки.

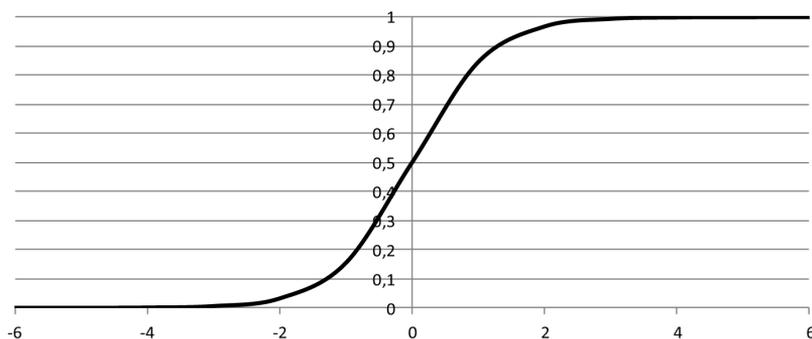


Рис. 7. Модель Г. Раша, представленная логистической функцией



Похожая логистическая функция (рис. 8) используется для представления зависимости способности принять правильное решение  $C(t)$  от продолжительности обдумывания решения  $t$ :

$$C(t) = C_{max} \left( \frac{e^{f(t-t_{cr})}}{1 + e^{f(t-t_{cr})}} - 0,5 \right)$$

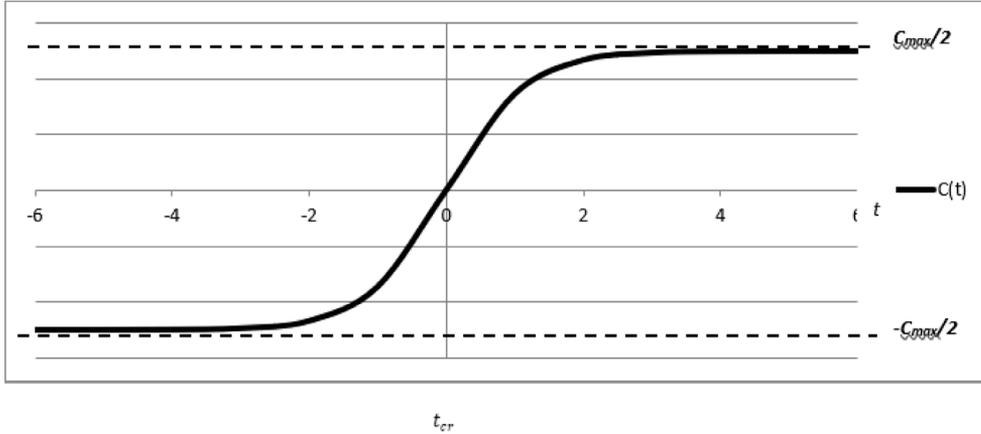


Рис. 8. Представление зависимости способности принять правильное решение от продолжительности обдумывания решения

Величина  $t_{cr}$  представляет индивидуальные особенности пилотов.

Далее полагаем, что величины  $t$  и  $t_{cr}$  безразмерны и измеряются в логитах:

$$t = \ln \left( \frac{t_{dim}}{t_{cr,dim}} \right)$$

где  $t_{dim}$  – размерное время,  $t_{cr,dim}$  – размерное критическое значение времени.

В этом случае  $t_{cr} = 0$ ,

$$C(t) = C_{max} \left( \frac{e^{ft}}{1 + e^{ft}} - 0,5 \right), \text{ а идентифицируемые параметры есть } C_{max} \text{ и } f.$$

Используем следующие результаты наблюдений:

- 1) матрицу  $\mathbf{M}_1$  правильности принятия решений при  $t \gg t_{cr}$ ;
- 2) матрицу  $\mathbf{M}_2$  правильности принятия решений при значениях  $t$ , имеющих порядок  $t_{cr}$  (полагается, что известны времена принятия решений  $t_{ij}$  для каждого пилота  $i$  и задания  $j$ ).

Матрицы правильности принятия решений имеют вид (единица представляет правильное решение, а 0 – неправильное).

$G_i$ – пилоты, $T_i$ – задания	$T_1$	$T_2$	...	$T_{n-1}$	$T_n$
$G_1$	0   1	0   1	0   1	0   1	0   1
$G_2$	0   1	0   1	0   1	0   1	0   1
...	0   1	0   1	0   1	0   1	0   1
$G_{m-1}$	0   1	0   1	0   1	0   1	0   1
$G_m$	0   1	0   1	0   1	0   1	0   1



Полагаем известной оценку  $a$ . Используя матрицу  $\mathbf{M}_1$ , для каждого задания  $T_i$  оцениваем его трудность  $D_i$  через частоту правильных решений. Для каждого пилота  $i$  методом максимального правдоподобия (ММП) при известном параметре  $a$  оцениваем способность  $C_{max,i}$  (однопараметрическая оптимизация).

Используя матрицу  $\mathbf{M}_2$  и способности  $C_{max,i}$ , найденные по матрице  $\mathbf{M}_1$ , перебираем значения  $f$  из заданного диапазона с шагом, равным заданной точности, находя значения  $t_{cr,i}$  для каждого пилота  $i$  с помощью ММП. Сравнивая ММП-оценки (логарифмы функций правдоподобия) по всем пилотам таблицы для рассмотренных значений  $f$ , получаем наиболее правдоподобную усредненную оценку параметра  $f$ .

Пусть  $R$  – продолжительность критической ситуации, а  $t_{r0} = q_0 R$  – продолжительность считывания информации с индикаторов ( $0 < q_0 < 1$ ). Предположим, что в результате тренировок время считывания информации изменилось в  $q$  раз:  $t_r = qq_0 R$ , где  $0 < q < 1$ . Тогда продолжительность обдумывания решения изменилась в  $r$  раз, где

$$r = \frac{R - qq_0 R}{R - q_0 R} = \frac{1 - qq_0}{1 - q_0}$$

Пусть  $t$  – старая продолжительность обдумывания решения, тогда  $t^* = rt$  – новая продолжительность обдумывания решения. При этом

$$C(t) = C_{max} \frac{e^{f(t-t_{cr})}}{1 + e^{f(t-t_{cr})}} = C_{max} \frac{e^{f(\frac{t^*}{r}-t_{cr})}}{1 + e^{f(\frac{t^*}{r}-t_{cr})}} = C_{max} \frac{e^{\frac{f}{r}(t^*-rt_{cr})}}{1 + e^{\frac{f}{r}(t^*-rt_{cr})}} = C(t^*).$$

Таким образом, при переходе к новой шкале времени после проведения сеанса тренировок  $f$  заменяется на  $\frac{f}{r}$ , а  $t_{cr}$  – на  $rt_{cr}$ . В шкале логитов выражение еще проще:

$$C(t^*) = C_{max} \frac{e^{\frac{f}{r}t^*}}{1 + e^{\frac{f}{r}t^*}}.$$

С целью упрощения, можно полагать, что  $C_{max}$  идентифицируется как общий параметр для всех пилотов.

Пусть значения  $q$  и  $q_0$  известны, а параметры  $C_{max}$ ,  $f$  и  $a$  идентифицированы по матрицам  $\mathbf{M}_1$  и  $\mathbf{M}_2$ . Полагая продолжительность обдумывания решения свободным параметром, просчитываем значения функции Г. Раша

$$p(C(t)-D) = \frac{e^{a(C(t)-D)}}{1 + e^{a(C(t)-D)}}$$

для различных значений времени  $t$  и значений трудностей заданий  $D$  из разумного диапазона (например,  $D \in [-3; 3]$ ) с заданным шагом в случае старого и нового времени считывания информации, представляя результаты в виде двух сопоставляемых графиков 3-D поверхностей  $p(t, D)$ .

Полагая величину  $t - t_{cr}$  нормально распределенной с известными параметрами (среднее значение равно нулю; стандартное отклонение оценивается по наблюдениям, определяющим  $t_{r0}$  и известному значению  $R$ ), можно оценить средние значения  $p(C(t)-D)$  для каждого значения трудности  $D$  в случае старого и нового времени считывания информации и сопоставить два полученных графика  $p_{mean}(D)$ . Это позволит оценить



изменение вероятности принятия правильного решения для различных трудностей заданий (ситуаций) после проведения сеанса тренировок, обусловленное как изменением времени считывания информации, так и совершенствованием навыков принятия правильного решения. Данный показатель можно использовать в качестве основной количественной оценки эффективности проведенных тренировок. Кроме того, в качестве *дополнительного показателя* можно использовать изменение по результатам тренировок среднего времени принятия решений  $t_{\text{mean}}$  для имеющейся выборки пилотов. Статистическую значимость изменения этого показателя можно оценить, используя параметрические и непараметрические критерии согласия для соответствующих выборок.

Используя результаты экспериментов на авиационном тренажере Ту-204, которые показали, что для удержания самолета на заданной траектории в режиме захода на посадку частота переноса взора пилота от одного контролируемого параметра к другому составляет 130–150 перемещений в минуту, и полагая оценку среднего времени фиксации взора равной 300 мс, оценку значения  $q_0$  можно в первом приближении принять равной

$$\frac{140 \times 300 \text{ мс}}{60 \times 1000 \text{ мс}} = 0,7 .$$

Значения величины  $q$  можно перебирать в разумном диапазоне, выбирая уровень, при котором будет достигнуто приемлемое увеличение вероятности принятия правильного решения для заданных трудностей заданий (ситуаций).

Продолжительность считывания и обработки информации с индикаторов  $t_{i0}$  в первом приближении можно оценивать как сумму продолжительностей фиксаций взора в течение критической ситуации с верхней границей в 320 мс (т. е. фиксации, продолжительности которых превышают 320 мс, учитываются как фиксации с продолжительностью 320 мс). Как показывают эксперименты, индивидуальные особенности пилотов на данную характеристику влияют достаточно слабо.

Пример логистической регрессии для оценки риска по одному из первичных показателей ГДА приведен на рис. 9. Исследуемым показателем ГДА являлось время, потраченное на обдумывание ситуации, планирование действий и принятие решений, оцениваемое по продолжительности фиксаций взора в процессе считывания и интерпретации показаний индикаторов (когда взгляд направлен на приборы, а не на окно кабины). Параметры логистической регрессии идентифицировались *методом максимального правдоподобия*.

## Основные результаты и выводы

1. Разработана модель рисков человеческого фактора при пилотировании воздушного судна. Эта модель построена на сравнениях представлений оцениваемых действий экипажей с сопоставимыми представлениями действий различных типов и качества исполнения, образующих репрезентативную выборку и содержащихся в заранее сформированной специализированной базе данных. Риск представляется вероятностными оценками, которые строятся в результате последовательного применения метода главных компонент, многомерного шкалирования и кластерного анализа к трем типам характеристик: параметрам полета и состояния систем воздушного судна, траекториям движения глаз и временным рядам первичных показателей глазодвигательной активности, — что приводит к формиро-

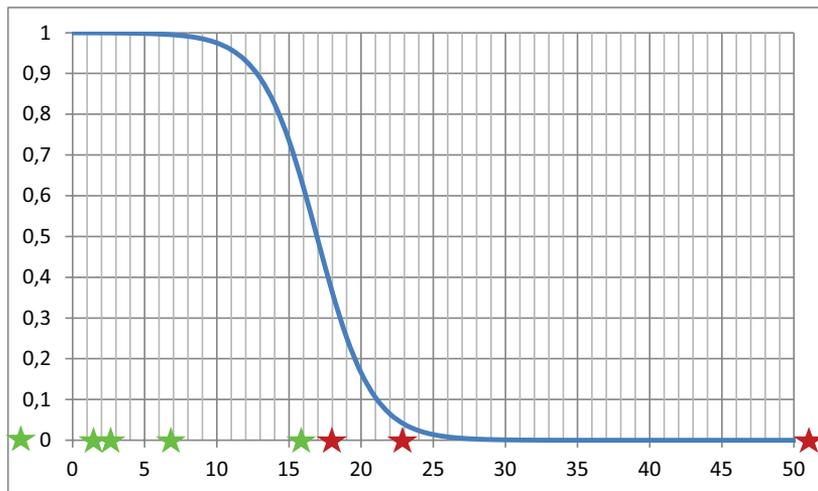


Рис. 9. Логистическая регрессия для оценки вероятности принятия правильного решения по продолжительности фиксации взгляда в процессе считывания и интерпретации показаний индикаторов (зеленые звездочки соответствуют успешно выполненным упражнениям, а красные — неудачным попыткам; по оси абсцисс отложен исследуемый показатель)

ванию кластеров фрагментов полетов различных типов и качества исполнения, включая аномальные. Дискриминантный анализ обеспечивает вычисление вероятностного профиля принадлежности к целевым кластерам, на основе которого строится итоговое заключение.

2. Ключевым элементом представленного подхода являются три новые метрики, применяемые для сравнений действий экипажей и обеспечивающие значимую дискриминацию фрагментов полетов различных типов и качества исполнения, а именно: евклидова метрика и метрика Кохонена для вейвлет-представлений различных вариантов работы экипажей, а также метрика правдоподобия траекторий собственных значений для преобразований параметров деятельности, — без применения, которых многомерное шкалирование и кластерный анализ не дали бы желаемый результат. Учитывая различную природу трёх применяемых метрик, целесообразно использовать их параллельно, сопоставляя полученные результаты.

3. Выполняется детализация вкладов параметров полета и состояния систем воздушного судна в различия фрагментов полетов в заданной метрике, результаты которой используются при содержательном анализе причин выявляемой аномальности.

4. В качестве упрощенного альтернативного подхода, вероятность риска оценивается по первичным показателям глазодвигательной активности, используя логистическую регрессию.

5. Полученные результаты позволяют создать классификационные правила для разделения различных уровней качества выполнения упражнений, а также их типов в пространстве шкалирования, при этом различия между кластерами различных вариантов выполнения одних и тех же упражнений объясняются тем, что их реализация обусловлена индивидуальными навыками.

6. Оценка рисков пилотирования сводится к определению вероятностей принадлежности к целевым кластерам, связанным с типами упражнений и качеством пилотирования.

7. При достаточной скорости вычислений, рассмотренный анализ полетных данных в автоматическом режиме может быть выполнен в реальном времени.



### Пример практического применения: автоматическая оценка рисков пилотирования в режиме реального времени

Далее представлены этапы анализа заданного (выполняемого) упражнения в автоматическом режиме, используя базу паттернов, содержащую пять качественно различных групп фрагментов полетов, составленных из 34 нормально и аномально выполненных летных упражнений, выполненных на универсальном стенде прототипирования ГосНИИАС. Оценка рисков пилотирования выполнялась в процессе выполнения заданного летного упражнения (32-я секунда полета), сразу по его завершении (64-я секунда полета) и спустя определенное время после завершения упражнения (128-я секунда полета). Анализ в автоматическом режиме выполнялся с помощью специальной версии *Intelligent System for Flight Analysis (ISFA 2.1)*.

При анализе заданного летного упражнения в процессе его выполнения были выполнены следующие операции:

- **32-я секунда полета:**

- выявлены параметры, представляющие главные компоненты (рис. 10);
- вычислены матрицы взаимных расстояний между реализациями летных упражнений в метрике вейвлет-коэффициентов и метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности (рис. 11);

- определены фрагменты полетов из базы паттернов, которые в указанных метриках являются ближайшими к заданному упражнению, при этом по информации, сопутствующей им в этой базе, определен тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» – аномальность) (рис. 12);

- в результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычислены распределение летных упражнений в пространстве шкалирования, результаты их кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров, при этом оценка вероятности принадлежности к типу «Восстановление из сложного пространственного положения» составила 0,89 (рис. 13);

- **64-я секунда полета:**

- выявлены параметры, представляющие главные компоненты;
- вычислены матрицы взаимных расстояний между реализациями летных упражнений в метрике вейвлет-коэффициентов и метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности (рис. 14);

- определены фрагменты полетов из базы паттернов, которые в указанных метриках являются ближайшими к заданному упражнению, при этом по информации, сопутствующей им в этой базе, подтвержден тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» – аномальность) (рис. 15);

- чтобы выявить, чем обусловлены различия исследуемого упражнения и эталонного упражнения типа «Восстановление из сложного пространственного положения» из базы паттернов, проведена оценка относительных вкладов параметров полета, определенных с



помощью метода главных компонент, в соответствующие элементы матриц взаимных расстояний, вычисленные в метрике вейвлет-коэффициентов, которая показала, что различие указанных фрагментов полета, в основном, определяется параметрами «Roll Euler Angle – Угол крена» и «Angle of attack – Угол атаки» (рис. 15);

– в результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычислены распределение летных упражнений в пространстве шкалирования, результаты их кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров, при этом оценка вероятности принадлежности к типу «Восстановление из сложного пространственного положения» составила 0,71 (рис. 16);

• **128-я секунда полета:**

– выявлены параметры, представляющие главные компоненты (рис. 17);

– вычислены матрицы взаимных расстояний между реализациями летных упражнений в метрике вейвлет-коэффициентов и метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности (рис. 18);

– определены фрагменты полетов из базы паттернов, которые в указанных метриках являются ближайшими к заданному упражнению, при этом по информации, сопутствующей им в этой базе, подтверждены тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» – аномальность) (рис. 19);

– чтобы подтвердить, чем обусловлены различия исследуемого упражнения и эталонного упражнения типа «Восстановление из сложного пространственного положения» из базы паттернов, проведена уточняющая оценка относительных вкладов параметров полета в соответствующие элементы матриц взаимных расстояний, которая, как и ранее, показала, что различие указанных фрагментов полета, в основном, определяется параметрами «Roll Euler Angle – Угол крена» и «Angle of attack – Угол атаки» (рис. 20);

– в результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычислены уточненное распределение летных упражнений в пространстве шкалирования, результаты их кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров, при этом оценка вероятности принадлежности к типу «Восстановление из сложного пространственного положения» составила 1,0 (рис. 20);

– с целью содержательного сопоставления динамики параметров, определяющих различия, исследуемого и эталонного упражнений, эти параметры представлены в форме, удобной для экспертной оценки (рис. 21).

*Очевидно, что, при достаточной скорости вычислений, рассмотренный анализ полетных данных в автоматическом режиме может быть выполнен в реальном времени. Оценка рисков пилотирования сводится к определению вероятностей принадлежности к целевым кластерам, связанным с типами упражнений и качеством пилотирования.*

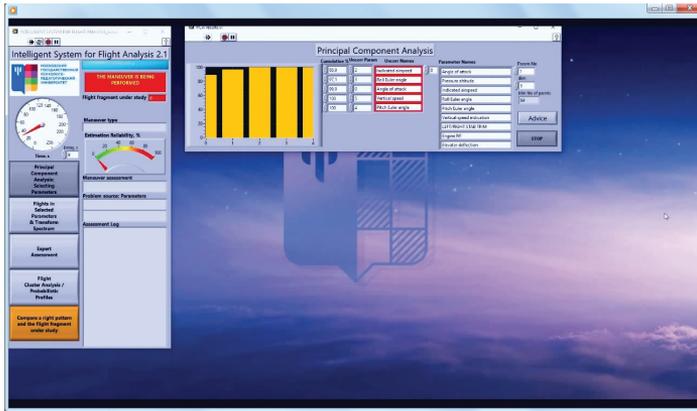


Рис. 10. Параметры, представляющие главные компоненты (32-я секунда полета)

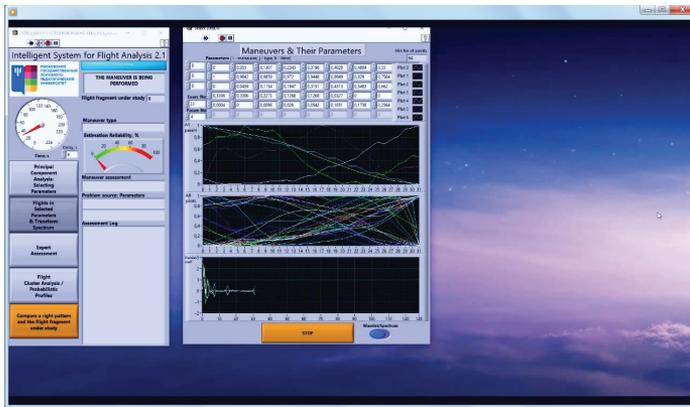


Рис. 11. Вычисление матриц взаимных расстояний между реализациями летных упражнений в заданных метриках (32-я секунда полета)

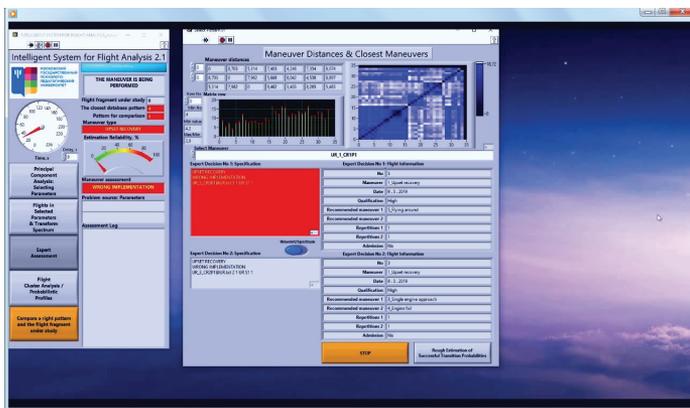


Рис. 12. Определение фрагментов полетов из базы паттернов, которые являются ближайшими к данному упражнению; при этом по информации, сопутствующей им в этой базе, определяется тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» – аномальность) (32-я секунда полета)

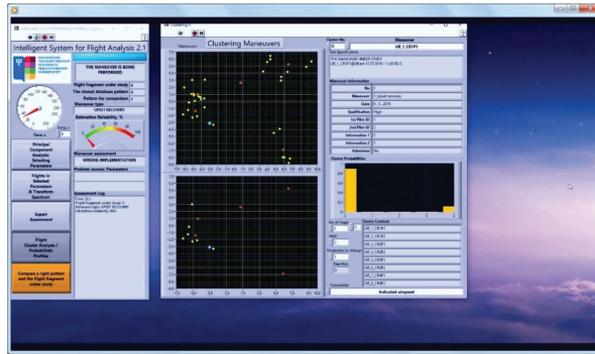


Рис. 13. В результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычисляется распределение летных упражнений в пространстве шкалирования. Представлены результаты кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров (32-я секунда полета)



Рис. 14. Вычисление матрицы взаимных расстояний между реализациями летных упражнений в метрике вейвлет-коэффициентов и метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности (64-я секунда полета)



Рис. 15. Определение фрагментов полетов из базы паттернов, которые являются ближайшими к заданному упражнению; при этом по информации, сопутствующей им в этой базе, подтверждены тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» — аномальность). Оценка относительных вкладов параметров полета в соответствующую матрицу взаимных расстояний показала, что различие фрагментов полета в основном определяется параметрами «Roll Euler Angle — Угол крена» и «Angle of attack — Угол атаки» (64-я секунда полета)

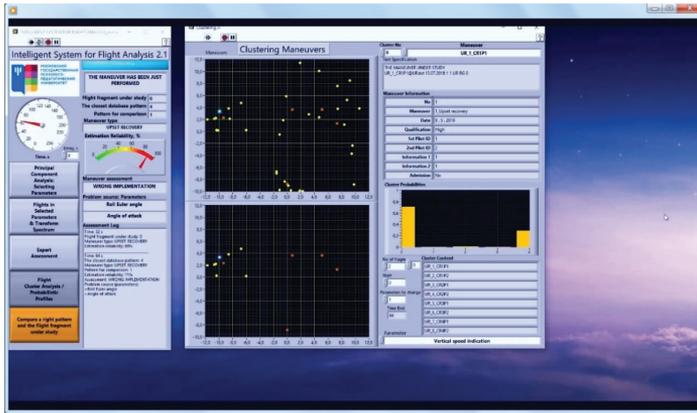


Рис. 16. В результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычисляется распределение летных упражнений в пространстве шкалирования. Представлены результаты кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров (64-я секунда полета)



Рис. 17. Параметры, представляющие главные компоненты (128-я секунда полета)

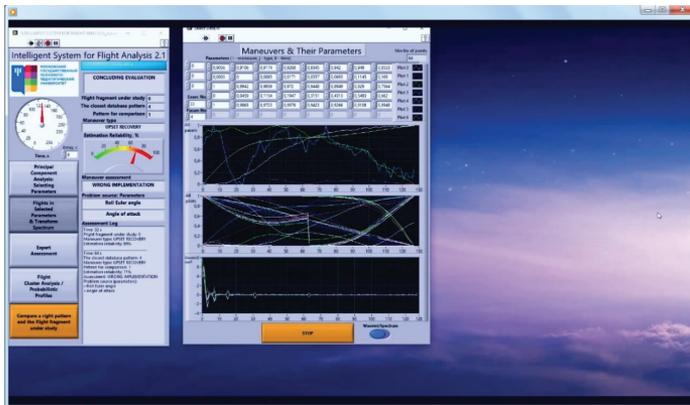


Рис. 18. Вычисление матрицы взаимных расстояний между реализациями летных упражнений в метрике вейвлет-коэффициентов и метрике правдоподобия траекторий собственных значений для преобразований параметров деятельности (128-я секунда полета)



Рис. 19. Определение фрагментов полетов из базы паттернов, которые являются ближайшими к заданному упражнению; при этом по информации, сопутствующей им в этой базе, подтверждены тип данного упражнения («Восстановление из сложного пространственного положения») и его качество («Wrong implementation» — аномальность). Оценка относительных вкладов параметров полета в соответствующие элементы матриц взаимных расстояний подтвердила, что различие фрагментов полета в основном определяется параметрами «Roll Euler Angle — Угол крена» и «Angle of attack — Угол атаки» (128-я секунда полета)

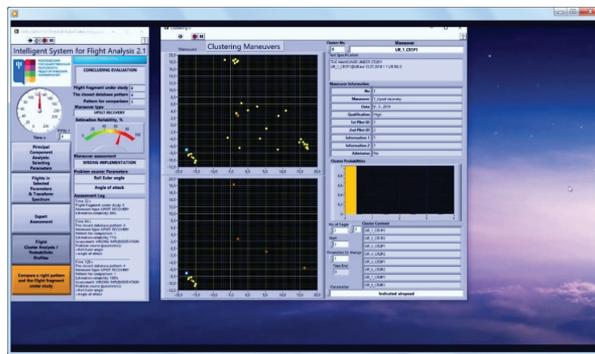


Рис. 20. В результате последовательного выполнения многомерного шкалирования, кластерного анализа и дискриминантного анализа вычисляется распределение летных упражнений в пространстве шкалирования. Представлены результаты кластеризации и оценки вероятностей принадлежности заданного упражнения к каждому из рассматриваемых кластеров (128-я секунда полета)

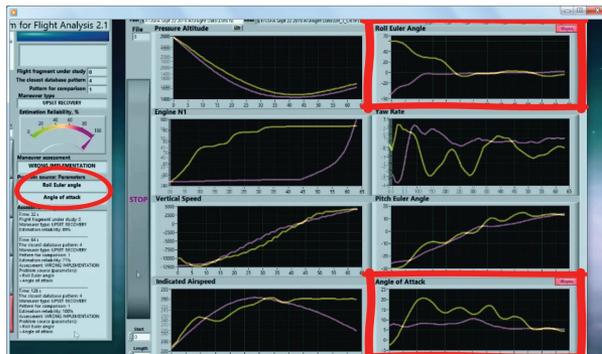


Рис. 21. С целью содержательного сопоставления динамики параметров, определяющих различия исследуемого и эталонного упражнений, эти параметры представлены в форме, удобной для экспертной оценки



## Литература

1. Aaron M. 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. P. 1–6.
3. Borg I., Groenen, P.J.F. Modern Multidimensional Scaling Theory and Applications. Springer, 2005. P.140.
4. Bress Thomas J. Effective LabVIEW Programming: NTS Press, 2013.
5. Cottrell M., Faure C., Lacaille J., Olteanu M. Anomaly Detection for Bivariate Signals. IWANN (1) 2019. P. 162–173.
6. Cramer H. Mathematical Methods of Statistics. Princeton: Princeton University Press, 1999. 575 p.
7. Eerland W.J., Box S. Trajectory Clustering, Modelling and Selection with the focus on Airspace Protection // AIAA Infotech@ Aerospace. AIAA, 2016. P. 1–14.
8. 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. P. 10–13.
9. 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. P. 22–25.
10. Faure C., Bardet J.M., Olteanu M., Lacaille J. Using Self-Organizing Maps for Clustering and Labelling Aircraft Engine Data Phases // WSOM. 2017. P. 96–103.
11. Gaffney S., Smyth P. Joint probabilistic curve clustering and alignment // Advances in Neural Information Processing Systems. 2005. Vol. 17. P. 473–480.
12. 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. P. 63–72.
13. Gariel M., Srivastava A., Feron E. Trajectory clustering and an application to airspace monitoring // IEEE Transactions on Intelligent Transportation Systems. 2011. Vol. 12. № 4. P. 1511–1524.
14. ГОСТ Р ИСО/МЭК 31010 – 2011. Менеджмент риска. Методы оценки риска. М.: Изд-во стандартов, 2011. 71 с.
15. 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. № 1. P. 129–138.
16. Hung C., Peng W., Lee W. Clustering and aggregating clues of trajectories for mining trajectory patterns and routes // The VLDB Journal – The International Journal on Very Large Data Bases. 2015. Vol. 24. № 2. P. 169–192.
17. Kohonen T. Self-Organizing Maps, Springer, 3th Ed., 2001. 501 pp.
18. Красильщиков М.Н., Евдокименков В.Н., Базлев Д.А. Индивидуально-адаптированные бортовые системы контроля технического состояния самолета и поддержки управляющих действий летчика. М.: Изд-во МАИ, 2011. 438 с.
19. Kuravsky L.S., Artemenkov S.L., Yuriev G.A., Grigorenko E.L. New approach to computer-based adaptive testing. Experimental Psychology. 2017. Vol. 10. № 3. P. 33–45. doi:10.17759/exppsy.2017100303
20. Куравский Л.С., Марголис А.А., Мармалюк П.А., Панфилова А.С., Юрьев Г.А. Математические аспекты концепции адаптивного тренажера. Психологическая наука и образование, 2016. Том. 21. № 2. С. 84–95. doi: 10.17759/pse.2016210210
21. Kuravsky L.S., Margolis A.A., Marmalyuk P.A., Panfilova A.S., Yuryev G.A., Dumin P.N. A Probabilistic Model of Adaptive Training [Электронный ресурс] // Applied Mathematical Sciences. Vol. 10. 2016. № 48. P. 2369–2380. URL: <http://dx.doi.org/10.12988/ams.2016.65168>
22. Куравский Л.С., Мармалюк П.А., Юрьев Г.А. Диагностика профессиональных навыков на основе вероятностных распределений глазодвигательной активности // Вестник РФФИ. 2016. № 3(91). С. 72–82.
23. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A. and Dumin P.N. A Numerical Technique for the Identification of Discrete-State Continuous-Time Markov Models [Электронный ресурс] // Applied Mathematical Sciences. 2015. Vol. 9. № 8. P. 379–391. URL: <http://dx.doi.org/10.12988/ams.2015.410882>



24. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A., Belyaeva O.B., Prokopenko O.Yu. Mathematical Foundations of Flight Crew Diagnostics Based on Videoculography Data [Электронный ресурс] // Applied Mathematical Sciences. 2016. Vol. 10. № 30. P. 1449–1466 URL: <http://dx.doi.org/10.12988/ams.2016.6122>
25. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A., Dumin P.N., Panfilova A.S. Probabilistic modeling of CM operator activity on the base of the Rasch model // Proc. 12th International Conference on Condition Monitoring & Machinery Failure Prevention Technologies. Oxford: UK, June, 2015.
26. Kuravsky L.S., Yuryev G.A. Probabilistic method of filtering artefacts in adaptive testing. Experimental Psychology. 2012. Vol. 5. № 1. P. 119–131.
27. Куравский Л.С., Юрьев Г.А. Свидетельство о государственной регистрации программы для ЭВМ № 2018660358 Intelligent System for Flight Analysis v1.0 (ISFA#1.0) / Правообладатели Куравский Л.С., Юрьев Г.А. (Россия). Заявка № 2018617617; Заявка 18.07.2018; Зарегистр. 22.08.2018. (РОСПАТЕНТ).
28. Kuravsky L.S., Yuryev G.A. Detecting abnormal activities of operators of complex technical systems and their causes basing on wavelet representations [Электронный ресурс] // International Journal of Civil Engineering and Technology (IJCIET). 2019. Vol. 10(2). Issue 02, February. P. 724–742. URL: [http://www.iaeme.com/MasterAdmin/UploadFolder/IJCIET\\_10\\_02\\_070/IJCIET\\_10\\_02\\_070.pdf](http://www.iaeme.com/MasterAdmin/UploadFolder/IJCIET_10_02_070/IJCIET_10_02_070.pdf). (дата обращения: 17.09.2019).
29. Kuravsky L.S., Yuryev G.A. On the approaches to assessing the skills of operators of complex technical systems // Proc. 15th International Conference on Condition Monitoring & Machinery Failure Prevention Technologies. Nottingham, UK, September 2018. P. 25.
30. 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. 2019. Vol. 12. № 4. P. 27–49. doi:10.17759/exppsy.2019120403
31. Laxhammar R., Falkman G. Online learning and sequential anomaly detection in trajectories // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2014. Vol. 36. № 6. P. 1158–1173.
32. Li Z., et al. Incremental clustering for trajectories // Database Systems for Advanced Applications. Lecture Notes in Computer Science. 2010. Vol. 5982. P. 32–46.
33. 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. P. 3716–3720.
34. Марковские модели в задачах диагностики и прогнозирования: Учеб. пособие 2-е изд., доп. / Под ред. Л.С. Куравского. М.: Изд-во МГППУ, 2017. 197 с.
35. Neal P.G. Multiresolution Analysis for Adaptive Refinement of Multiphase Flow Computations // University of Iowa. 2010. P. 116.
36. René Vidal, Yi Ma, Shankar Sastry. Generalized Principal Component Analysis [Электронный ресурс]. New York: Springer-Verlag, 2016. URL: <http://www.springer.com/us/book/9780387878102>
37. Rintoul M., Wilson A. Trajectory analysis via a geometric feature space approach // Statistical Analysis and Data Mining: The ASA Data Science Journal. 2015.
38. Trevor F. Cox, M.A.A. Cox. Multidimensional Scaling, Second Edition. Chapman & Hall/CRC, 2001. P. 299.
39. Wei J., et al. Design and Evaluation of a Dynamic Sectorization Algorithm for Terminal Airspace // Journal of Guidance, Control, and Dynamics. 2014. Vol. 37. № 5. P. 1539–1555.
40. Wilson A., Rintoul M., Valicka C. Exploratory Trajectory Clustering with Distance Geometry // International Conference on Augmented Cognition / Springer. 2016. P. 263–274.
41. Xiangyu Kong, Changhua Hu, Zhansheng Duan. Principal Component Analysis Networks and Algorithms [Электронный ресурс]. Springer, 2017. P. 322. URL: <http://www.springer.com/us/book/9789811029134>

## References

1. Aaron M. 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. International Workshop on Machine Learning for Signal Processing (MLSP) / IEEE. 2014, pp. 1–6.



3. Borg, I., Groenen, P. J. F. *Modern Multidimensional Scaling Theory and Applications*. Springer, 2005. P. 140.
4. Bress, Thomas J. *Effective LabVIEW Programming*: NTS Press, 2013. ISBN 1-934891-08-8.
5. Cottrell M., Faure C., Lacaille J., Olteanu M. *Anomaly Detection for Bivariate Signals*. IWANN (1) 2019, pp. 162–173.
6. Cramer H. *Mathematical Methods of Statistics*. Princeton: Princeton University Press. 1999. P. 575.
7. Eerland W.J., Box S. *Trajectory Clustering, Modelling and Selection with the focus on Airspace Protection*. AIAA Infotech@ Aerospace. \_ AIAA, 2016, pp. 1–14.
8. 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.
9. 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.
10. Faure C., Bardet J.M., Olteanu M., Lacaille J. Using Self-Organizing Maps for Clustering and Labelling Aircraft Engine Data Phases. In: WSOM 2017, pp. 96–103.
11. 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.
12. 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.
13. 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.
14. GOST R ISO/MEHK 31010 – 2011 Menedzhment riska. Metody otsenki riska. [Risk management. Risk assessment methods]. Moscow: Standartov Pub-l, 2011. P.71.
15. 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.
16. Hung C., Peng W., Lee W. Clustering and aggregating clues of trajectories for mining trajectory patterns and routes. *The VLDB Journal – The International Journal on Very Large Data Bases*. 2015. Vol. 24, no. 2, pp. 169–192.
17. Kohonen T. *Self-Organizing Maps*. Springer, 3th Ed., 2001. P. 501.
18. Krasil'shchikov M.N., Evdokimenkov V.N., Bazlev D.A. Individual'no-adaptirovannye bortovye sistemy kontrolya tekhnicheskogo sostoyaniya samoleta i podderzhki upravlyayushchikh deistvii letchika [Individually adapted on-Board systems for monitoring the technical condition of the aircraft and supporting the pilot's control actions]. Moscow: MAI Pub-l, 2011. P. 438.
19. Kuravsky L.S., Artemenkov S.L., Yuriev G.A., Grigorenko E.L. New approach to computer-based adaptive testing. *Experimental Psychology*. 2017. Vol. 10. No. 3, pp. 33–45. doi:10.17759/exppsy.2017100303.
20. Kuravskii L.S., Margolis A.A., Marmalyuk P.A., Panfilova A.S., Yur'ev G.A. Matematicheskie aspekty kontseptsii adaptivnogo trenazhera [Mathematical aspects of the concept of the adaptive motion trainer]. *Psikhologicheskaya nauka i obrazovanie [Psychological Science and Education (Russia)]*, 2016, V. 21, № 2, pp. 84–95. (In Russ.; abstract in Engl.) doi: 10.17759/pse.2016210210
21. Kuravsky L.S., Margolis A.A., Marmalyuk P.A., Panfilova A.S., Yuryev G.A., Dumin P.N. A Probabilistic Model of Adaptive Training. *Applied Mathematical Sciences*, Vol. 10, 2016, no. 48, pp. 2369 – 2380. URL: <http://dx.doi.org/10.12988/ams.2016.65168> (Accessed 15.03.2020).
22. Kuravskii L.S., Marmalyuk P.A., Yur'ev G.A. Diagnostika professional'nykh navykov na osnove veroyatnostnykh raspredelenii glazodvigatel'noi aktivnosti [Diagnostics of professional skills based on probabilistic distributions of oculomotor activity]. *Vestnik RFFI [Bulletin RFFI (Russia)]*, 2016, №3(91), pp. 72–82.
23. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A. and Dumin P.N. A Numerical Technique for the Identification of Discrete-State Continuous-Time Markov Models. *Applied Mathematical Sciences*. Vol. 9, 2015, No. 8, pp. 379–391. URL: <http://dx.doi.org/10.12988/ams.2015.410882> (Accessed 15.03.2015).
24. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A., Belyaeva O.B. and Prokopieva O.Yu. Mathematical Foundations of Flight Crew Diagnostics Based on Videoculography Data. *Applied Mathematical Sciences*, Vol. 10, 2016, no. 30, pp. 1449–1466. URL: <http://dx.doi.org/10.12988/ams.2016.6122> (Accessed 15.03.2020).



25. Kuravsky L.S., Marmalyuk P.A., Yuryev G.A., Dumin P.N., Panfilova A.S. Probabilistic modeling of CM operator activity on the base of the Rasch model. *In: Proc. 12th International Conference on Condition Monitoring & Machinery Failure Prevention Technologies*, Oxford, UK, June 2015.
26. Kuravsky L.S., Yuriev G.A. Probabilistic method of filtering artefacts in adaptive testing. *Experimental Psychology*, Vol.5, No. 1, 2012, pp. 119–131.
27. Kuravskii L.S., Yur'ev G.A. Svidetel'stvo o gosudarstvennoi registratsii programmy dlya EHVM №2018660358 Intelligent System for Flight Analysis v1.0 (ISFA#1.0) / Pravoobladateli Kuravskii L.S., Yur'ev G.A. (Russia). – Zayavka №2018617617; Zayav. 18.07.2018; Zaregistr. 22.08.2018. – (ROSPATENT).
28. 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)*. Vol. 10(2). Issue 02, February 2019, pp. 724–742. URL: [http://www.iaeme.com/MasterAdmin/UploadFolder/IJCIET\\_10\\_02\\_070/IJCIET\\_10\\_02\\_070.pdf](http://www.iaeme.com/MasterAdmin/UploadFolder/IJCIET_10_02_070/IJCIET_10_02_070.pdf) (Accessed 17.09.2019).
29. Kuravsky L.S., Yuryev G.A. On the approaches to assessing the skills of operators of complex technical systems. *In: Proc. 15th International Conference on Condition Monitoring & Machinery Failure Prevention Technologies*, Nottingham, UK, September 2018. P. 25.
30. Kuravsky L.S., Yuryev G.A., Zlatomrezhev V.I. New approaches for assessing the activities of operators of complex technical systems. *Экспериментальная психология [Experimental psychology (Russia)]*, 2019, vol. 12, no. 4, pp. 27–49. (In Russ.; abstract in Engl.) doi:10.17759/exppsy.2019120403
31. 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.
32. Li Z., et al. Incremental clustering for trajectories. *Database Systems for Advanced Applications. Lecture Notes in Computer Science*. 2010. Vol. 5982, pp. 32–46.
33. Liu H., Li J. Unsupervised multi-target trajectory detection, learning and analysis in complicated environments. 21st International Conference on Pattern Recognition (ICPR) / IEEE. 2012, pp. 3716–3720.
34. Markovskie modeli v zadachakh diagnostiki i prognozirovaniya [Markov models in the problems of diagnostics and forecasting]: Ucheb. posobie /Pod red. L.S. Kuravskogo. 2-e izd., dop. Moscow: MGPPU Pub-1, 2017. P. 197.
35. Neal P.G. Multiresolution Analysis for Adaptive Refinement of Multiphase Flow Computations. *University of Iowa*, 2010. P. 116.
36. René Vidal, Yi Ma, Shankar Sastry. Generalized Principal Component Analysis. *Springer-Verlag*: New York, 2016. URL: <http://www.springer.com/us/book/9780387878102> (Accessed 15.03.2020).
37. Rintoul M., Wilson A. Trajectory analysis via a geometric feature space approach. *Statistical Analysis and Data Mining: The ASA Data Science Journal*. 2015.
38. Trevor F. Cox, M.A.A. Cox. Multidimensional Scaling, Second Edition. *Chapman & Hall*. CRC, 2001. P. 299.
39. 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.
40. Wilson A., Rintoul M., Valicka C. Exploratory Trajectory Clustering with Distance Geometry. *International Conference on Augmented Cognition*. *Springer*. 2016, pp. 263–274.
41. Xiangyu Kong, Changhua Hu, Zhansheng Duan. Principal Component Analysis Networks and Algorithms. *Springer*, 2017. P. 322. URL: <http://www.springer.com/us/book/9789811029134> (Accessed 15.03.2020).

### **Информация об авторах**

*Куравский Лев Семенович*, доктор технических наук, профессор, декан факультета информационных технологий, Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация, ORCID: <http://orcid.org/0000-0002-3375-8446>, e-mail: [ls.kuravsky@gmail.com](mailto:ls.kuravsky@gmail.com)

*Юрьев Григорий Александрович*, кандидат физико-математических наук, доцент, заведующий научной лабораторией, 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)

*Златомрежев Валентин Игоревич*, заведующий лабораторией, Государственный научно-исследовательский институт авиационных систем (ФГУП «ГосНИИАС»), г. Москва, Российская Федерация, ORCID: <https://orcid.org/0000-0003-1776-6881>, e-mail: [vizlatomr@2100.gosniias.ru](mailto:vizlatomr@2100.gosniias.ru)

*Юрьева Наталия Евгеньевна*, кандидат технических наук, научный сотрудник, Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация, ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: [yurieva.ne@gmail.com](mailto:yurieva.ne@gmail.com)

### **Information about the authors**

*Lev S. Kuravsky*, DSc (Engineering), Professor, Dean of Computer Science Faculty, Moscow State University of Psychology and Education, 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 (Physics and Mathematics), Associate Professor, Head of Scientific Laboratory, Moscow State University of Psychology and Education, ORCID: <https://orcid.org/0000-0002-2960-6562>, e-mail: [g.a.yuryev@gmail.com](mailto:g.a.yuryev@gmail.com)

*Valentin I. Zlatomrezhev*, Head of Laboratory, State Research Institute of Aviation Systems (GosNIIAS), ORCID: <https://orcid.org/0000-0003-1776-6881>, e-mail: [vizlatomr@2100.gosniias.ru](mailto:vizlatomr@2100.gosniias.ru)

*Nataliya E. Yurieva*, PhD (Engineering), Research fellow, Moscow State University of Psychology and Education, Research Associate, ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: [yurieva.ne@gmail.com](mailto:yurieva.ne@gmail.com)

Получена 09.03.2020

Принята в печать 20.04.2020

Received 09.03.2020

Accepted 20.04.2020