

Д.И. КРАСНОВ, М.А. ВОЛЫНСКИЙ, А.А. ГУСЕВ  
**ОЦЕНКА СОСТОЯНИЯ АГЕНТА С ДИНАМИКОЙ  
СТОХАСТИЧЕСКОГО ХАРАКТЕРА С ПОМОЩЬЮ  
РЕКУРРЕНТНЫХ ФИЛЬТРОВ**

*Краснов Д.И., Волынский М.А., Гусев А.А. Оценка состояния агента с динамикой стохастического характера с помощью рекуррентных фильтров.*

**Аннотация.** В работе представлен метод оценки состояния агента многоагентной биологической системы по зашумленным измерениям с помощью рекуррентных фильтров. Рассмотрена проблема масштабируемости существующих подходов к регистрации поведения лабораторных грызунов и отсутствия единого математического описания. Приведено математическое описание агента биологической системы как нелинейной дискретной стохастической системы в пространстве состояний и постановка задачи оценки его состояния. Представлено решение поставленной задачи на примере ключевых точек крысы линии Wistar, которые измеряются с помощью предварительно обученного детектора. В работе предлагается использовать полносвязную нейронную сеть для параметризации неизвестной динамики системы. Для сравнительного анализа выбраны фильтр частиц (последовательный метод Монте-Карло) и ансцентный фильтр Калмана. Сравнение методов производилось на собранном и подготовленном наборе данных, который содержит изображения с разрешением 1060×548 и разметку скелетных точек крысы. Представленные результаты экспериментов по сравнению методов оценки состояния показывают высокую эффективность предложенного метода и его преимущество перед аналитическим описанием нелинейной динамики системы. Среди сравниваемых подходов минимальную среднюю ошибку 6,4 пикселей показала двойная оценка вектора состояния и параметров нейронной сети с помощью двух ансцентных фильтров Калмана. Однако для практического применения в реальном времени больше подходит один фильтр с предварительно обученной нейронной сетью. В таких условиях ансцентный фильтр Калмана показал лучшие результаты по точности, чем фильтр частиц (средняя ошибка 8,1 пикселя против 12,0 пикселей). Результаты работы могут быть использованы для решения задачи автоматической регистрации поведения крыс линии Wistar с помощью параметризации функций, связывающих векторы состояния с выходными векторами индивидуального и группового поведения.

**Ключевые слова:** ключевые точки скелета, лабораторные животные, многоагентная биологическая система, ансцентный фильтр Калмана, фильтр частиц, нейронная сеть, оценка вектора состояния.

**1. Введение.** Многоагентный подход в современном системном анализе, теории управления и искусственном интеллекте предполагает использование децентрализованных агентов для моделирования и управления сложными системами. В рамках такого подхода под агентом понимается реальная или виртуальная сущность, функционирующая во внешней среде. Агента можно описать с помощью системы, которая имеет определенный набор состояний и перечень возможных действий. При этом агент способен проявлять как индивидуальное независимое поведение, так и взаимодействовать с другими агентами, проявляя групповое или социальное поведение.

Многоагентный подход или агентное моделирование позволяет описывать достаточно широкий класс сложных систем, переходя от простейшего взаимодействия между агентами к общему моделированию всей системы. При этом существует множество различных прикладных задач, для которых применяется многоагентное моделирование [1], но в контексте данной работы удобно разделить эти задачи на две группы. К первой группе относятся задачи, связанные с моделированием и симуляцией развития и динамики сложных систем. Примером таких задач является анализ экологических систем, динамики популяции животных, симуляция биологических систем [2] или поведения пешеходов с помощью динамики социального взаимодействия [3]. Для таких задач характерно большое количество агентов, имеющих достаточно простое математическое описание, позволяющее эффективно масштабировать модель, моделируя развитие системы. В этом случае на первый план выходит глобальное состояние многоагентной системы (МАС) и ее макроскопические параметры, а агент имеет вспомогательную роль.

Другой задачей является распределенное или сетевое управление. Обзорные работы по сетевому управлению [4, 5] рассматривают МАС с позиции классической теории управления. В рамках такого представления агент характеризуется с помощью динамической системы с входом и выходом, например в пространстве состояний, а взаимодействие между агентами описывается с помощью графа, ребра которого представляют связи между отдельными агентами. Динамика агента при этом описывается простой системой, например интегратором, а задачей является синтез законов распределенного управления для роения, следования за лидером, следования в заданную точку или исследования неизвестного пространства. Распределенность и децентрализованность управления в таких задачах обусловлены двумя факторами. Во-первых, агенты являются относительно автономными сущностями, а связи между ними возникают только в момент управления, то есть граф связей изменяется во времени [5]. Во-вторых, каждый агент обладает информацией только о ближайших или соседних агентах, что является одной из сложностей сетевого управления.

Такое представление характерно для задач коллективного управления беспилотными летательными аппаратами [6–9] или наземными роботами [10, 11]. При таком подходе поведение отдельно взятого агента так же не является существенным, поскольку основной идеей сетевого управления является достижение коллективной цели. Чаще всего динамика агентов при таком подходе известна, так как

речь идет о программируемых роботах, однако существуют работы [12], посвященные оптимальным алгоритмам управления МАС с использованием параметрической идентификации с помощью линейной регрессионной модели.

В качестве другого примера задачи коллективного управления и класса МАС, в которых возникает такая задача, можно выделить футбол роботов. Данный пример интересен сравнительно малым количеством взаимодействующих агентов и вниманием к индивидуальному поведению каждого агента, что отличает футбол роботов от задач управления группой беспилотных летательных аппаратов. Внимание к описанию индивидуального поведения необходимо, поскольку динамика и закон управления агентами команды противника неизвестны. Для футбола роботов характерны задачи оптимального расположения агентов на поле (сетевое управление) [13, 14] и объезда движущегося препятствия (индивидуальное управление) [15]. Основной сложностью для синтеза закона управления в футболе роботов является неопределенность в движении агентов команды противника. Поэтому большинство законов индивидуального управления сводится в детектировании агента противника и объезда его как препятствия, согласно заранее определенной динамике движения.

В контексте данной работы интерес представляют системы, имеющие как сложную или неизвестную стохастическую динамику, так и сложное взаимодействие между агентами. Например, в работе [16] рассматривается система из корабля и нескольких буксиров, задача управления которой заключается в перемещении корабля в определенную точку посредством тяги буксиров под воздействием возмущений окружающей среды. Другим примером является управление роботизированной репликой рыбы с помощью обратной связи [17 – 21]. Данная задача представляет особый интерес, поскольку роботизированная реплика рыбы должна мимикрировать под естественные движения живой рыбы, чтобы не вызывать отторжение у живых рыб в ходе исследования взаимодействия между ними. Поэтому необходимо учитывать как индивидуальное поведение реплики, то есть траекторию движения, так и групповое поведение, то есть реакцию на движение других рыб с помощью обратной связи. Обратная связь в данной задаче заключается в адаптации движения роботизированной рыбы к траектории движения и поведению живых рыб, которые анализируются с помощью обработки видеопотока с камеры в реальном времени. Основной сложностью является моделирование неизвестной стохастической динамики живой рыбы,

что предполагает проработку сложного математического описания [22 – 25], основанного на анализе собранных экспериментальных данных, поскольку детерминированное описание в данной задаче невозможно. Анализ траекторий движений рыбы *Danio rerio* показал, что изменение ее угловой скорости во времени обладает определенной авторегрессионностью [23]. Это позволило моделировать изменение угловой и линейной скоростей с помощью стохастического процесса Орнштейна-Уленбека, параметры которого определялись с помощью метода максимального правдоподобия.

В случае роботизированной реплики рыбы задача управления сводится к моделированию траектории движения, в которой необходимо учесть периоды неподвижности, движение вдоль стенок аквариума и движение при наличии других рыб. Однако, существует класс МАС, агенты которых имеют более сложное индивидуальное поведение и групповое взаимодействие. Сложность заключается в широком перечне возможных поведенческих активностей, которые выходят за рамки траекторного описания. Для таких систем не характерна задача управления, поскольку на передний план выступает задача анализа как поведения отдельного агента, так и взаимодействия между агентами. Ярким примером являются многоагентные биологические системы, например система лабораторных грызунов, взаимодействующих в закрытом боксе. Примером задачи анализа таких систем является задача автоматизации длительного мониторинга поведения лабораторных животных с помощью компьютерного зрения [26, 27]. Отличительной особенностью в данной задаче является агентоориентированный подход, в котором поведение отдельного агента, эволюция его поведенческого профиля и межагентное взаимодействие имеют большее значение, чем динамика всей системы в целом. Такой подход позволяет не только объединить имеющиеся решения по мониторингу поведения лабораторных грызунов [28 – 30], но и обеспечить масштабируемость между различными биологическими системами, что в настоящее время затруднено из-за высокой степени специализации каждого решения.

Другой сложностью анализа таких МАС, как и в задаче управления роботизированной репликой рыбы, является неизвестная стохастическая динамика системы. Результаты работ [31, 32] показывают, что в пространственных траекториях движения лабораторных грызунов существуют взаимосвязи и паттерны, которые возможно выделить с помощью методов машинного обучения. Однако математическое описание стохастической динамики лабораторного грызуна является сложной задачей, которая может быть решена только

с помощью подходов, связанных с использованием большого количества экспериментальных данных. Например, выделенные в ходе анализа экспериментальных данных паттерны движения мыши могут быть использованы для построения стохастической модели движения животного, аналогично модели движения рыбы в работе [23]. Отдельным вопросом для исследования является переносимость и масштабируемость такой модели не только на различные виды грызунов (мыши и крысы), но даже на различных особей одного вида, поскольку каждая особь обладает своим индивидуальным поведенческим профилем, который может не соответствовать модели.

Как было отмечено ранее, сложность и многоуровневость поведения агентов также является особенностью, которую необходимо учитывать при разработке алгоритмов анализа таких МАС. В существующих подходах к анализу поведения агентов на примере лабораторных грызунов прослеживается узкая направленность не только по типам взаимодействия (индивидуальное и социальное), но и по множеству возможных действий внутри одного типа взаимодействия. Например, в работе [28] анализируется социальное взаимодействие двух мышей на примере трех классов: нападение, запрыгивание на другую особь, обнюхивание. В работе [33] представлен анализ индивидуального поведения белой крысы на примере классов: питье, прием пищи, груминг, обнюхивание, ходьба, прыжок, отдых и вставание на задние лапы. Однако среди существующих подходов не найдены решения, позволяющие одновременно регистрировать как индивидуальное поведение агента, так и социальное взаимодействие между агентами.

На основе проведенного анализа можно сделать вывод о том, что большинство существующих подходов к анализу, моделированию и управлению МАС рассматривают системы с большим количеством агентов, имеющих сравнительно простое математическое описание и известную динамику, что позволяет их эффективно масштабировать. Лишь небольшое количество работ посвящено анализу МАС, характеризующихся малым количеством агентов со сложной или неизвестной стохастической динамикой и сложным взаимодействием между агентами.

Поэтому целью данной работы является постановка и решение задачи оценки состояния агента МАС по зашумленным измерениям на примере крысы линии Wistar. Оценка состояния необходима для анализа индивидуального поведения агента и взаимодействия между агентами, как будет показано в дальнейшем. Новизна данной работы заключается в достаточно общей постановке задачи анализа МАС,

которая включает в себя описание дискретной нелинейной стохастической системы в пространстве состояний, где в качестве вектора состояния выступает вектор ключевых точек, а в качестве выходного вектора – вектор вероятности совершения действия из множества возможных. Кроме того, представленный вектор вероятности поведений может быть разделен на индивидуальное и коллективное типы поведения, переключаемые с помощью весовой функции. Описанный подход применим для анализа МАС, для которых характерен вероятностный характер динамики и сложное взаимодействие между агентами, предполагающее широкий спектр возможных действий. В случае автоматической регистрации поведения лабораторных грызунов представленный подход может объединить анализ как индивидуального поведения агента, так и социального взаимодействия между агентами, что будет способствовать повышению качества медицинских исследований.

В настоящей статье представлено продолжение предыдущего исследования по оценке вектора состояния биологической системы по зашумленным измерениям [34]. Целью предыдущей работы было определить наиболее подходящее аналитическое описание динамики агента биологической системы. В ходе исследования был получен набор данных с траекториями ключевых точек крысы линии Wistar, расширенная версия которого используется в данной работе. А результаты исследования показали, что ни одна из детерминированных аналитических моделей движения не может в полной мере описать динамику биологического агента. Поэтому в данной работе для параметризации модели динамики системы предлагается использовать полносвязную нейронную сеть. Приведенные результаты показывают преимущество описанного подхода по сравнению с аналитической нелинейной моделью движения.

**2. Постановка задачи.** Рассмотрим в качестве описания  $i$ -го агента нелинейную дискретную систему в пространстве состояний:

$$\begin{aligned} \mathbf{X}_i(k+1) &= \mathbf{f}(\mathbf{X}_i(k), \mathbf{w}(k)) \\ \begin{bmatrix} \mathbf{y}_i^{\text{ind}}(k) \\ \mathbf{y}_{ij}^{\text{soc}}(k) \end{bmatrix} &= \begin{bmatrix} (1 - \max(\alpha_{ij}(k))) \mathbf{h}^{\text{ind}}(\mathbf{X}_i(k)) \\ \alpha_{ij}(k) \mathbf{h}^{\text{soc}}(\mathbf{X}_i(k), \mathbf{X}_j(k)) \end{bmatrix}, \end{aligned} \quad (1)$$

где  $\mathbf{X}_i(k) = [\mathbf{x}_i(k - K_{\text{prev}}) \dots \mathbf{x}_i(k)]^T$  – вектор, составленный из векторов состояния  $\mathbf{x}_i(k)$   $i$ -го агента за  $K_{\text{prev}}$  предыдущих моментов

времени, где  $i=1, \dots, N$ ;  $k$  – номер отсчета, где  $k=1, \dots, K$ ;  $\mathbf{X}_i(0) = \mathbf{X}_{i0}$  – начальное состояние системы;  $\mathbf{w}(k)$  – вектор шума, обусловленный ошибкой математической модели;  $\mathbf{f}(\cdot)$  – нелинейная функция, описывающая динамику системы;  $\mathbf{y}_i^{\text{ind}}(k)$  – недоступный для измерения выходной вектор индивидуального поведения  $i$ -го агента;  $\mathbf{y}_{ij}^{\text{soc}}(k)$  – недоступный для измерения выходной вектор группового поведения  $i$ -го и  $j$ -го агентов, где  $i, j=1, \dots, N$ ,  $i \neq j$ ;  $\mathbf{h}^{\text{ind}}(\cdot)$  – неизвестная нелинейная функция, связывающая предыдущие  $K_{\text{prev}}$  векторов состояния  $i$ -го агента с вектором индивидуального поведения  $i$ -го агента;  $\mathbf{h}^{\text{soc}}(\cdot)$  – неизвестная нелинейная функция, связывающая предыдущие  $K_{\text{prev}}$  векторов состояния  $i$ -го и  $j$ -го агентов с вектором группового поведения  $i$ -го и  $j$ -го агентов;  $\alpha_{ij}$  – коэффициент связи между  $i$ -м и  $j$ -м агентами;  $N$  – общее количество агентов;  $K$  – общее количество отсчетов.

По системе (1) можно увидеть, что агенты являются однородными, то есть функции  $\mathbf{f}(\cdot)$ ,  $\mathbf{h}^{\text{ind}}(\cdot)$  и  $\mathbf{h}^{\text{soc}}(\cdot)$  одинаковы для каждого агента. Функции, описывающие индивидуальные и коллективные действия агента независимы. Более того, индивидуальные и коллективные действия агента в момент времени  $k$  исключают друг друга, то есть агент может совершать либо индивидуальные действия, либо коллективные, что определяется коэффициентами связи. Коэффициенты связи между агентами  $\alpha_{ij}$  представляют собой аналог ребер графа, который используется для описания попарного взаимодействия между агентами в алгоритмах сетевого управления. В данной работе предлагается вычислять коэффициенты связи как смещенную и отраженную функцию Хевисайда, которая реализует переключение между индивидуальным и групповым поведением:

$$\alpha_{ij}(k, d_{ij}) = \begin{cases} 1, & d_{ij} < d_{\max} \\ 0, & d_{ij} \geq d_{\max} \end{cases}, \quad (2)$$

где  $d_{ij}$  – Евклидово расстояние между центрами масс  $i$ -го и  $j$ -го агентов;  $d_{\max}$  – максимальное расстояние, при котором взаимодействие считается парным.

Анализ многоагентной биологической системы в данном контексте заключается в определении неизвестных выходных векторов  $\mathbf{y}_i^{\text{ind}}(k)$  и  $\mathbf{y}_{ij}^{\text{soc}}(k)$ , представляющих собой векторы вероятностей совершения агентом того или иного действия из заранее определенных множеств индивидуальных и социальных активностей. Определить эти

векторы возможно только с помощью решения задачи идентификации неизвестных нелинейных функций  $\mathbf{h}^{\text{ind}}(\cdot)$  и  $\mathbf{h}^{\text{soc}}(\cdot)$  на основе предыдущих оценок векторов состояния и истинных значений выходных векторов. Решение этой задачи выходит за рамки данной работы, поскольку она посвящена задаче оценки вектора состояния по зашумленным измерениям.

Вектор состояния в задаче анализа поведения агента биологической системы может представлять собой координаты ключевых точек скелета грызуна за последние  $K_{\text{prev}}$  кадров. Рассмотрим задачу оценки вектора состояния агента. Для простоты ограничимся рассмотрением автономного агента (крыса находится в боксе одна). Тогда математическое описание системы (1) примет вид:

$$\begin{aligned} \mathbf{X}(k+1) &= \mathbf{f}(\mathbf{X}(k), \mathbf{w}(k)) \\ \mathbf{z}(k) &= \mathbf{H}\mathbf{X}(k) + \mathbf{v}(k) \end{aligned} \quad (3)$$

где  $\mathbf{H}$  – матрица измерения, связывающая векторы состояния с вектором измеряемых параметров  $\mathbf{z}(k)$ ;  $\mathbf{v}(k)$  – белый гауссовский шум измерений с нулевым математическим ожиданием и ковариационной матрицей  $\mathbf{R}$ ;  $k$  – номер отсчета, где  $k=1, \dots, K$ ;  $K$  – общее количество отсчетов.

Стоит отметить, что функция динамики системы  $\mathbf{f}(\cdot)$  может быть задана несколькими способами. Например, в предыдущей работе [34] было предложено использовать линейную модель равноускоренного движения [35] и нелинейную модель Constant Turn Rate and Acceleration (CTRA) [36]. В данной работе предлагается параметризовать динамику системы с помощью полносвязной нейронной сети или многослойного перцептрона (MLP):

$$\begin{aligned} \mathbf{X}(k+1) &= \mathbf{f}(\mathbf{X}(k), \boldsymbol{\theta}, \mathbf{w}(k)) \\ \mathbf{z}(k) &= \mathbf{H}\mathbf{X}(k) + \mathbf{v}(k) \end{aligned} \quad (4)$$

где  $\boldsymbol{\theta}$  – вектор параметров;  $k$  – номер отсчета, где  $k=1, \dots, K$ ;  $K$  – общее количество отсчетов.

Вектор параметров  $\boldsymbol{\theta}$  содержит веса полносвязной нейронной сети, а его размерность зависит от длины вектора состояния, количества слоев сети и количества нейронов в скрытых слоях (в данной работе его размерность равна 866). Этот вектор может быть определен либо с помощью градиентных методов по критерию минимизации оценочного функционала (среднеквадратическая



ошибка) на основе собранных ранее экспериментальных данных, либо с помощью двойной оценки в процессе работы рекуррентного фильтра, как это предложено в работе [37].

**3. Материалы и методы.** В данной работе был использован тот же набор данных, что в работе [34]. В качестве вектора состояния агента  $x(k)$  использован вектор, составленный из координат  $x$ ,  $y$  ключевых точек скелетной модели крысы (рисунок 1), которые были выбраны экспертом по поведению. Скелетная модель крысы состоит из 13-ти точек: нос (1); правый и левый глаз (2 и 3); правое и левое ухо (5 и 6); средняя точка головы (4); средняя точка пояса передних конечностей (7); средняя точка позвоночника (8); правая и левая передняя конечность (9 и 10); основание хвоста (11); правая и левая задняя конечность (12 и 13). Набор данных содержит около 3 тыс. изображений с разрешением  $1060 \times 548$  и разметкой ключевых точек скелета. Стоит отметить, что исходные видеозаписи сняты в так называемой обогащенной среде, то есть в бокс с крысой дополнительно помещены веревки и домики из органического стекла, что создает дополнительные помехи и окклюзии отдельных частей крысы.




Рис. 1. Расположение точек скелета на крысе [34]

В качестве вектора  $X(k)$  используется вектор, составленный из ключевых точек за  $K_{\text{prev}}$  предыдущих кадров. В данной работе использовалось три последних кадра. Вектором зашумленных измерений  $z(k)$  являются предсказания детектора ключевых точек [38], обученного на экспериментальных данных. Детектор точек предсказывает точки в прямоугольной области кадра с крысой, которая выделяется с помощью обученного детектора объектов [39]. В качестве прямоугольника, ограничивающего зону кадра с крысой во время обучения детектора объектов, был использован прямоугольник минимального размера, содержащий все ключевые точки крысы на

данном кадре, поскольку отдельная разметка прямоугольной области с крысой не производилась. Тогда ковариационной матрицей шума измерения  $\mathbf{R}$  является диагональная матрица, диагональ которой составлена из дисперсий ошибок детектора точек для координат  $x$  и  $y$  каждой точки:

$$\text{diag}(\mathbf{R}) = \left[ \sigma_{x1}^2 \quad \sigma_{y1}^2 \quad \dots \quad \sigma_{xN_{kp}}^2 \quad \sigma_{yN_{kp}}^2 \right], \quad (5)$$

где  $\sigma_{xi}^2$  и  $\sigma_{yi}^2$  – дисперсии ошибок детектора точек для координат  $x$  и  $y$  соответственно;  $N_{kp}$  – количество ключевых точек (в данной работе 13).

Например, для координаты  $x$  для  $i$ -й точки:

$$\sigma_{xi}^2 = \frac{1}{M-1} \sum_{j=1}^M (\Delta x_i(j) - \Delta x_{im})^2, \quad (6)$$

где  $M$  – количество изображений в выборке;  $\Delta x_i(j)$  – разность между истинным и предсказанным сверточной сетью положением  $i$ -ой ключевой точки по координате  $x$  на  $j$ -ом изображении из выборки;  $\Delta x_{im}$  – среднее значение  $\Delta x_i(j)$  для всех изображений из выборки.

Тогда систему (4) можно дополнить, определив матрицу  $\mathbf{H}$  и приняв допущение, что шум  $\mathbf{w}(k)$  так же является белым Гауссовским шумом с нулевым математическим ожиданием и ковариационной матрицей  $\mathbf{Q}$ :

$$\begin{aligned} [\mathbf{x}(k+1) \quad \dots \quad \mathbf{x}(k-K+1)]^T &= \mathbf{f}([\mathbf{x}(k) \quad \dots \quad \mathbf{x}(k-K)]^T, \boldsymbol{\theta}) + \mathbf{w}(k) \\ \mathbf{z}(k) &= \begin{bmatrix} \mathbf{I}_{2N_{kp} \times 2N_{kp}} & 0 \\ 0 & 0 \end{bmatrix} [\mathbf{x}(k) \quad \dots \quad \mathbf{x}(k-K)]^T + \mathbf{v}(k) \end{aligned} \quad (7)$$

Главной задачей для оценки состояния системы является определение функции  $\mathbf{f}(\cdot)$ . Функция  $\mathbf{f}(\cdot)$  в данной работе параметризована с помощью полносвязной нейронной сети с одним скрытым слоем, содержащим 8 нейронов. В качестве ковариационной матрицы шума модели  $\mathbf{Q}$  можно использовать диагональную матрицу, элементы диагонали которой рассчитаны по выражениям (5) и (6) аналогично матрице  $\mathbf{R}$  и дополнены нулями после  $2N_{kp}$ -го элемента, поскольку ошибка параметризации для  $\mathbf{x}(k)$  не влияет на векторы состояния за  $K_{\text{prev}}$  предыдущих кадров. В данной работе оценка

вектора состояния системы (7) проведена с помощью ансцентного фильтра Калмана (UKF) [40] и фильтра частиц (PF) или последовательного метода Монте-Карло тремя способами: UKF с определенным в процессе обучения нейронной сети вектором параметров, двойным UKF (Dual UKF) для параллельной оценки вектора параметров [37] и мультиоблачным последовательным методом Монте-Карло [41]. Для сравнения с описанными выше методами в качестве динамики системы была использована нелинейная модель СТРА с UKF, как в работе [34].

В случае использования аналитической нелинейной модели СТРА функция  $\mathbf{f}(\cdot)$  не нуждается в параметризации, а вектор состояния дополняется скоростью, ускорением, углом поворота и угловой скоростью для каждой ключевой точки скелетной модели. Кроме того, не учитывается история предыдущих  $K_{\text{prev}}$  векторов состояния для обновления состояния агента, что приводит к упрощению модели.

В случае предварительного обучения полностью связанной нейронной сети для параметризации динамики (методы MLP с UKF и MLP с PF) используется ориентированный на данных подход. Нейронная сеть была обучена предсказывать следующий вектор состояния (множество ключевых скелетных точек) по  $K_{\text{prev}}$  предыдущим ключевым точкам этой траектории, минимизируя среднеквадратическую ошибку между координатами предсказанной точки и истинной точки. Обученная сеть с замороженными весами использовалась в процессе работы фильтров. Для UKF использовалась реализация, предложенная в работе [40]. В качестве PF использовалась реализация последовательного мультиоблачного метода Монте-Карло, предложенная в работе [41], основная идея которого состоит в генерации нескольких облаков частиц вокруг оцененных векторов состояния с максимальным весом, вместо использования одного постоянного облака частиц. Для пересчета веса частиц использовалось распределение вероятности  $\mathbf{p}(\mathbf{z}(k)|\mathbf{X}(k))$ , связанное с невязкой предсказания (с учетом дальнейшего масштабирования веса каждой частицы):

$$\mathbf{p}(\mathbf{z}(k), \mathbf{X}(k)) = \exp\left(-\frac{1}{2}(\mathbf{z}(k) - \mathbf{H}\mathbf{X}(k))^T \mathbf{R}^{-1}(\mathbf{z}(k) - \mathbf{H}\mathbf{X}(k))\right). \quad (8)$$

На каждом шаге алгоритма происходил выбор нескольких частиц с наибольшим весом, удаление остальных частиц и генерация новых частиц вокруг выбранных, для того чтобы общее количество частиц осталось неизменным.

Метод MLP с dual UKF предполагает онлайн оценку параметров параметризованной модели динамики с помощью второго UKF [37]. Таким образом, два фильтра работают совместно, оценка параметров модели от одного фильтра используется для оценки вектора состояния в другом фильтре. В таком случае систему (7) можно расширить с помощью модели параметров в пространстве состояний:

$$\begin{aligned} \boldsymbol{\theta}(k+1) &= \boldsymbol{\theta}(k) + \mathbf{I}(k) \\ \mathbf{z}(k) &= \begin{bmatrix} \mathbf{I}_{2N_{kp} \times 2N_{kp}} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{f}\left([\mathbf{x}(k) \ \dots \ \mathbf{x}(k-K)]^T, \boldsymbol{\theta}(k)\right) + \mathbf{w}(k) + \mathbf{v}(k), \end{aligned} \quad (9)$$

где  $\boldsymbol{\theta}(k)$  и  $\boldsymbol{\theta}(k+1)$  – векторы параметров модели в моменты времени  $k$  и  $k+1$ ;  $\mathbf{I}(k)$  – вектор белого Гауссовского шума с нулевым математическим ожиданием и ковариационной матрицей  $\mathbf{L}$ .

Система (9) используется одним из двух UKF для онлайн оценки параметров нейронной сети. Вектор шума  $\mathbf{I}(k)$  помогает фильтру оценивать оптимальные параметры модели и введен в систему для лучшей сходимости алгоритма. Ковариационная матрица  $\mathbf{L}$  представляет собой диагональную матрицу с очень маленькими числами на главной диагонали (в эксперименте порядка  $10^{-6}$ ).

Для оценки точности сравниваемых методов из экспериментального набора данных было выбрано 26 траекторий ключевых точек по 100 кадров в каждой. В качестве ошибки использовалось Евклидово расстояние между истинной точкой траектории и точкой, полученной с помощью каждого рекуррентного фильтра, усредненное между всеми точками данного кадра. Средняя ошибка определяется по выражению:

$$e_m(k) = \frac{1}{N_{kp} T} \sum_{t=1}^T \sum_{n=1}^{N_{kp}} \sqrt{(x(t, n, k) - x^*(t, n, k))^2 + (y(t, n, k) - y^*(t, n, k))^2}, \quad (10)$$

где  $k$  – номер кадра в траектории;  $t$  – номер траектории;  $n$  – индекс ключевой точки;  $T$  – общее количество траекторий;  $x(t, n, k)$  и  $y(t, n, k)$  – координаты  $x$  и  $y$  точки с индексом  $n$ , предсказанной на кадре  $k$  траектории  $t$ ;  $x^*(t, n, k)$  и  $y^*(t, n, k)$  – истинные координаты  $x$  и  $y$  точки с индексом  $n$  на кадре  $k$  траектории  $t$ .

Визуализация вычислительного эксперимента представлена на рисунке 2. Эксперимент проводился на процессоре Intel Core i5-10300H. Математические операции и рекуррентные фильтры

реализованы на языке Python с помощью библиотек PyTorch и NumPy. Обучение и запуск детектора объектов производилось с помощью библиотеки MMDetection, а детектора ключевых точек с помощью библиотеки MMPose.

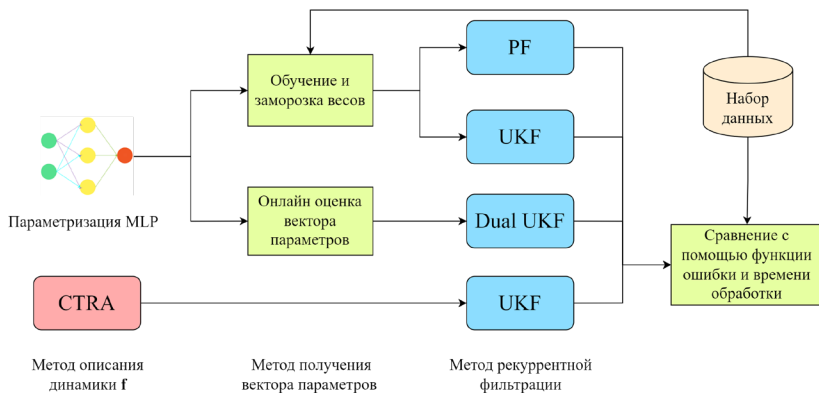


Рис. 2. Схема вычислительного эксперимента

**4. Результаты и обсуждение.** Результаты оценки точности каждого метода представлены как графики ошибки на каждом кадре по выражению (10). Ошибки представлены для четырех методов: UKF с параметризованной динамикой системы (MLP с UKF), двойной UKF для параллельной оценки вектора состояния и вектора параметров (MLP с dual UKF), аналитическая нелинейная модель СТРА с UKF (СТРА с UKF) и фильтр частиц с параметризованной динамикой системы (MLP с PF). На рисунке 3 представлены графики среднего значения ошибки с доверительным интервалом для каждого метода. Можно заметить характерную форму графика ошибки для MLP с dual UKF. Такая форма объясняется тем, что фильтру необходимо время для сходимости, поскольку оценка параметров модели выполняется в реальном времени. Ограниченность графиков ошибок демонстрирует сходимость описанных методов.

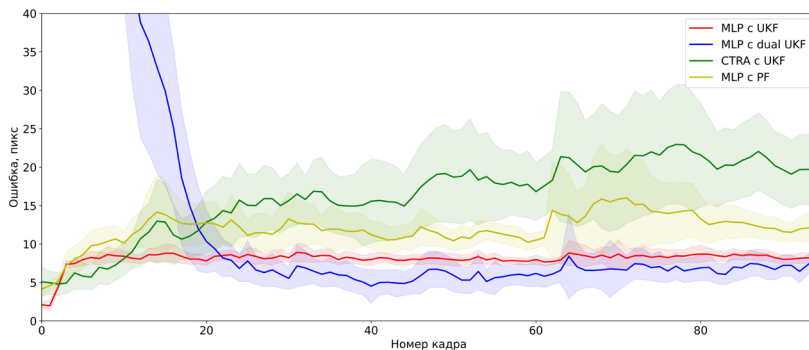


Рис. 3. Графики ошибок каждого метода

На рисунке 4 представлены коробчатые диаграммы ошибки каждого метода после точки сходимости. В качестве критерия сходимости использовалась ограниченность производной ошибки (10) (производная ошибки меньше 1,5 пикселя по модулю в течение 10-ти кадров), показывающая, что ошибка достигла своего рабочего значения и значительно не возрастает.




Рис. 4. Коробчатые диаграммы ошибок каждого метода

В первую очередь, результаты показывают применимость каждого из представленных методов в задаче оценки вектора состояния агента биологической системы. При этом заметно, что

параметризация динамики с помощью полносвязной нейронной сети позволяет более точно оценивать вектор состояния по сравнению с нелинейной моделью СТРА. Кроме того, такой метод в комбинации с UKF или фильтром частиц требует меньше времени на обработку, чем СТРА с UKF. В таблице 1 представлено время обработки одного кадра для каждого метода, математическое ожидание, среднее квадратическое отклонение (СКО) ошибки после сходимости и время сходимости. Результаты в таблице для PF приведены для 10 тыс. частиц. Ограниченность ошибки и небольшие значения СКО показывают сходимость и устойчивость рекуррентных фильтров, примененных в данной работе.

Таблица 1. Время обработки одного кадра и ошибка

Метод	MLP с UKF	MLP с Dual UKF	СТРА с UKF	MLP с PF
Время, мс	12	142	50	57
Мат. ожидание ошибки, пикс	8,1	6,4	16,3	12,0
СКО ошибки, пикс	2,3	4,4	13,7	7,9
Время сходимости (номер отсчета)	13	28	11	13

Таблица 1 показывает, что оценка состояния с помощью UKF с предобученной нейронной сетью для параметризации динамики имеет меньшую ошибку (8,1 пикс) и меньшую скорость обработки одного кадра (12 мс), чем PF (12,0 пикс и 57 мс). Отдельного внимания заслуживает метод с параллельной оценкой параметров нейронной сети с помощью двойного UKF. Этот метод показал наименьшую ошибку на тестовых данных (6,4 пикс) и наибольшее время обработки (142 мс), что делает его применение для обработки в реальном времени затруднительным. Наибольшую ошибку оценки состояния показал метод, основанный на аналитической нелинейной модели СТРА (16,3 пикс), что показывает преимущество параметризации динамики для МАС такого класса.

Однако в задачах анализа поведения лабораторных животных чаще всего необходима обработка видеозаписей, что не накладывает строгих ограничений на время обработки одного кадра и время выдачи результата, поэтому для данной задачи справедливо считать двойной UKF для оценки вектора состояния и вектора параметров модели лучшим. В случае необходимости обработки в реальном

времени возможно использовать одиночный UKF, высокая скорость обработки которого позволяет производить вычисления в том числе на одноплатных микрокомпьютерах, таких как NVIDIA Jetson Nano или RK3588.

**5. Заключение.** В данной работе представлено математическое описание агента в МАС со сложной стохастической динамикой и разделением индивидуального и группового поведения. Представленное описание предполагает агентоориентированный подход, для которого индивидуальное поведение агента и взаимодействие между агентами важнее, чем глобальная эволюция системы. Приведена постановка задачи оценки вектора состояния агента по зашумленным измерениям и ее решение на примере ключевых точек крысы линии Wistar. Показана применимость рекуррентных фильтров с параметризацией динамики системы с помощью полносвязной нейронной сети для решения поставленной задачи. Показано, что параметризация динамики системы позволяет уменьшить ошибку оценки вектора состояния по сравнению с использованием аналитической нелинейной модели СТРА.

Среди сравниваемых методов наиболее точной оказалась двойная оценка состояния и параметров модели с помощью двух UKF (ошибка 6,4 пикс), однако такой подход является самым ресурсозатратным и может быть применен в случае отсутствия строгих требований к скорости обработки одного кадра и скорости выдачи результата. Использование обученной нейронной сети с неизменяемыми параметрами с UKF позволило произвести оценку состояния с меньшей ошибкой, чем при использовании PF (ошибки 8,1 и 12,0 пикс соответственно), а короткое время обработки одного кадра (12 мс) позволяет использовать метод для обработки в реальном времени.

Главным направлением будущей работы является идентификация функций  $\mathbf{h}^{\text{ind}}(\cdot)$  и  $\mathbf{h}^{\text{soc}}(\cdot)$  на основе собранных данных для установления связи между оценками вектора состояния за предыдущее время и выходным вектором. Это позволит решить общую задачу анализа МАС представленного типа, поскольку выходные векторы представляют собой вероятности совершения различных видов индивидуального и группового поведения.

Использованный в работе набор данных, содержащий изображения и размеченные ключевые точки скелета крысы линии Wistar, является уникальным по отношению к имеющимся аналогам для мышей и крыс другого цвета. Набор данных вместе с исходным



кодом может быть предоставлен для исследовательских целей по запросу (Краснов Д.И., dmitriy\_krasnov@outlook.com).

Авторы выражают благодарность д-ру мед. наук Алексею Андреевичу Шмонину (Первый Санкт-Петербургский государственный медицинский университет им. акад. И.П. Павлова) за постановку задачи, предоставление записей видеонаблюдения за поведением крыс и экспертное мнение при разметке ключевых точек скелета.

## Литература

1. Кузнецов А.В. Краткий обзор многоагентных моделей // Управление большими системами: сборник трудов. 2018. № 71(5). С. 6–44. DOI: 10.25728/ubs.2018.71.1.
2. Bernardi S., Scianna M. An agent-based approach for modelling collective dynamics in animal groups distinguishing individual speed and orientation // Philosophical Transactions of the Royal Society B. 2020. vol. 375. DOI: 10.1098/rstb.2019.0383.
3. Rashid M.M., Seyedi M., Jung S. Simulation of pedestrian interaction with autonomous vehicles via social force model // Simulation Modelling Practice and Theory. 2024. vol. 132. DOI: 10.1016/j.simpat.2024.102901.
4. Antonelli G. Interconnected dynamic systems: An overview on distributed control // IEEE Control Systems Magazine. 2013. vol. 33. no. 1. pp. 76–88. DOI: 10.1109/MCS.2012.2225929.
5. Proskurnikov A.V., Fradkov A.L. Problems and methods of network control // Autom Remote Control. 2016. vol. 77. pp. 1711–1740. DOI: 10.1134/S0005117916100015.
6. Xue Y., Chen W. Multi-Agent Deep Reinforcement Learning for UAVs Navigation in Unknown Complex Environment // IEEE Transactions on Intelligent Vehicles. 2024. vol. 9. no. 1. pp. 2290–2303. DOI: 10.1109/TIV.2023.3298292.
7. Zhao X., Yang R., Zhong L., Hou Z. Multi-UAV Path Planning and Following Based on Multi-Agent Reinforcement Learning // Drones. 2024. vol. 8. no. 1. DOI: 10.3390/drones8010018.
8. Shi H., Zhao Z., Chen J., Zhou M., Liu Y. Enhancing Unmanned Aerial Vehicle Path Planning in Multi-Agent Reinforcement Learning through Adaptive Dimensionality Reduction // Drones. 2024. vol. 8. no. 10. DOI: 10.3390/drones8100521.
9. Podelenyuk, P., Epifantsev I. Modeling the Formation of a Multi-Agent System as a System of Points of a Rigid // IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus). 2021. pp. 594–597. DOI: 10.1109/EIConRus51938.2021.9396179.
10. Cong Y., Feng Z., Song H., Wang S. Containment control of singular heterogeneous multi-agent systems // Journal of the Franklin Institute. 2018. vol. 355. no. 11. pp. 4629–4643. DOI: 10.1016/j.jfranklin.2018.04.009.
11. Thummalapeda M., Liu Y.-C. Survey of containment control in multi-agent systems: concepts, communication, dynamics, and controller design // International Journal of Systems Science. 2023. vol. 54. no. 14. pp. 2809–2835.
12. Luo R., Peng Z., Hu J. On Model Identification Based Optimal Control and its Applications to Multi-Agent Learning and Control // Mathematics. 2023. vol. 11. no. 4. DOI: 10.3390/math11040906.
13. Iarosh D., Reneva G., Kornilova A., Kononov P. Multiagent System of Mobile Robots for Robotic Football // 26th Saint Petersburg International Conference on Integrated Navigation Systems (ICINS). 2019. pp. 1–3. DOI: 10.23919/ICINS.2019.8769365.

14. Ribeiro A.F.A., Lopes A.C.C., Ribeiro T.A., Pereira N.S.S.M., Lopes G.T., Ribeiro A.F.M. Probability-Based Strategy for a Football Multi-Agent Autonomous Robot System // *Robotics*. 2024. vol. 13. no. 1. DOI: 10.3390/robotics13010005.
15. Dewantara B.S.B., Ariyadi B.N.D. Adaptive Behavior Control for Robot Soccer Navigation Using Fuzzy-based Social Force Model // *Smart Science*. 2021. vol. 9. no. 1. pp. 14–29. DOI: 10.1080/23080477.2021.1871799.
16. Du Z., Negenborn R.R., Reppa V. Cooperative Multi-Agent Control for Autonomous Ship Towing Under Environmental Disturbances // *IEEE/CAA Journal of Automatica Sinica*. 2021. vol. 8. no. 8. pp. 1365–1379. DOI: 10.1109/JAS.2021.1004078.
17. Bonnet F., Gribovskiy A., Halloy J., Mondada F. Closed-loop interactions between a shoal of zebrafish and a group of robotic fish in a circular corridor // *Swarm Intelligence*. 2018. vol. 12. no. 3. pp. 227–244. DOI: 10.1007/s11721-017-0153-6.
18. Kim C., Ruberto T., Phamduy P., Porfiri M. Closed-loop control of zebrafish behaviour in three dimensions using a robotic stimulus // *Scientific Reports*. 2018. vol. 8. no. 1. DOI: 10.1038/s41598-017-19083-2.
19. Kopman V., Laut J., Polverino G., Porfiri M. Closed-loop control of zebrafish response using a bioinspired robotic-fish in a preference test // *Journal of The Royal Society Interface*. 2013. vol. 10. no. 78. DOI: 10.1098/rsif.2012.0540.
20. Swain D.T., Couzin I.D., Ehrlich Leonard N. Real-Time Feedback-Controlled Robotic Fish for Behavioral Experiments with Fish Schools // *Proceedings of the IEEE*. 2012. vol. 100. no. 1. pp. 150–163. DOI: 10.1109/JPROC.2011.2165449.
21. Landgraf T., Bierbach D., Nguyen H., Muggelberg N., Romanczuk P., Krause J. RoboFish: increased acceptance of interactive robotic fish with realistic eyes and natural motion patterns by live Trinidadian guppies // *Bioinspiration & Biomimetics*. 2016. vol. 11. no. 1. DOI: 10.1088/1748-3190/11/1/015001.
22. Collignon B., Séguret A., Halloy J. A stochastic vision-based model inspired by zebrafish collective behaviour in heterogeneous environments // *Royal Society Open Science*. 2016. vol. 3. no. 1. DOI: 10.1098/rsos.150473.
23. Mwaffo V., Anderson R.P., Butail S., Porfiri M. A jump persistent turning walker to model zebrafish locomotion // *Journal of The Royal Society Interface*. 2015. vol. 12. no. 102. DOI: 10.1098/rsif.2014.0884.
24. Zienkiewicz A.K., Ladu F., Barton D.A.W. Data-driven modelling of social forces and collective behaviour in zebrafish // *Journal of Theoretical Biology*. 2018. vol. 443. pp. 39–51. DOI: 10.1016/j.jtbi.2018.01.011.
25. Tuqan M., Porfiri M. Mathematical Modeling of Zebrafish Social Behavior in Response to Acute Caffeine Administration // *Frontiers in Applied Mathematics and Statistics*. 2021. vol. 7. DOI: 10.3389/fams.2021.751351.
26. van Dam E.A., Noldus L.P.J.J., van Gerven M.A.J. Deep learning improves automated rodent behavior recognition within a specific experimental setup // *Journal of Neuroscience Methods*. 2020. vol. 332. DOI: 10.1016/j.jneumeth.2019.108536.
27. Grieco F., Bernstein B.J., Biemans B. et al. Measuring Behavior in the Home Cage: Study Design, Applications, Challenges, and Perspectives // *Frontiers in Behavioral Neuroscience*. 2021. vol. 15. DOI: 10.3389/fnbeh.2021.735387.
28. Segalin C., Williams J., Karigo T. et al. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice // *eLife*. 2021. vol. 10. DOI: 10.7554/eLife.63720.
29. Hsu A.I., Yttri E.A. B-SO<sub>2</sub>D, an open-source unsupervised algorithm for identification and fast prediction of behaviors // *Nature Communications*. 2021. vol. 12. DOI: 10.1038/s41467-021-25420-x.
30. Ru Z., Duan F. Hierarchical Spatial-Temporal Window Transformer for Pose-Based Rodent Behavior Recognition // *IEEE Transactions on Instrumentation and Measurement*. 2024. vol. 73. pp. 1–14. DOI: 10.1109/TIM.2024.3379081.

31. Weinreb C., Pearl J.E., Lin S. et al. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics // *Nature Methods*. 2024. vol. 21. pp. 1329–1339. DOI: 10.1038/s41592-024-02318-2.
32. Donnarumma F., Prevete R., Maisto D. et al. A framework to identify structured behavioral patterns within rodent spatial trajectories // *Scientific Reports*. 2021. vol. 11. DOI: 10.1038/s41598-020-79744-7.
33. van Dam E.A., Noldus L.P.J.J., van Gerven M.A.J. Disentangling rodent behaviors to improve automated behavior recognition // *Front. Neurosci*. 2023. vol. 17. DOI: 10.3389/fnins.2023.1198209.
34. Краснов Д.И., Волинский М.А., Гусев А.А. Предобработка траекторий ключевых точек скелета в задаче автоматизации регистрации поведения лабораторных животных // *Научно-технический вестник информационных технологий, механики и оптики*. 2025. Т. 25. № 2. С. 295–302.
35. Buizza C., Fischer T., Demiris Y. Real-Time Multi-Person Pose Tracking using Data Assimilation // *IEEE Winter Conference on Applications of Computer Vision (WACV)*. 2020. pp. 438–447. DOI: 10.1109/WACV45572.2020.9093442.
36. Svensson D. Derivation of the discrete-time constant turn rate and acceleration motion model // *Sensor Data Fusion: Trends, Solutions, Applications (SDF)*. 2019. pp. 1–5. DOI: 10.1109/SDF.2019.8916654.
37. Yuan H., Han Y., Zhou Y. et al. State of Charge Dual Estimation of a Li-ion Battery Based on Variable Forgetting Factor Recursive Least Square and Multi-Innovation Unscented Kalman Filter Algorithm // *Energies*. 2022. vol. 15. no. 4. DOI: 10.3390/en15041529.
38. Huang J., Zhu Z., Guo F., Huang G. The Devil Is in the Details: Delving into Unbiased Data Processing for Human Pose Estimation // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2020. pp. 5699–5708. DOI: 10.1109/CVPR42600.2020.00574.
39. Lyu C., Zhang W., Huang H. et al. RTMDet: An Empirical Study of Designing Real-Time Object Detectors. 2024. arXiv preprint arXiv:2212.07784.
40. Wan E. A., Van Der Merwe R. The unscented Kalman filter for nonlinear estimation // *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No.00EX373)*. 2000. pp. 153–158. DOI: 10.1109/ASSPCC.2000.882463.
41. Волинский М.А., Гуров И.П., Скаков П.С. Рекуррентный алгоритм обработки интерферометрических сигналов на основе мультиоблачной модели предсказания // *Научно-технический вестник информационных технологий, механики и оптики*. 2014. Т. 14. № 4. С. 18–22.

**Краснов Дмитрий Игоревич** — аспирант, научно-образовательная лаборатория «Техническое зрение», Университет ИТМО. Область научных интересов: компьютерное зрение, распознавание образов, обработка изображений, искусственный интеллект. Число научных публикаций — 7. dmitriy\_krasnov@outlook.com; Кронверкский проспект, 49, 197101, Санкт-Петербург, Россия; р.т.: +7(996)189-3418.

**Волинский Максим Александрович** — канд. техн. наук, доцент, директор, научно-образовательная лаборатория «Техническое зрение», Университет ИТМО. Область научных интересов: вычислительная фотоника, биофотоника, взаимодействие оптического излучения с веществом, стохастическая обработка квазипериодических сигналов. Число научных публикаций — 130. maxim.volynsky@gmail.com; Кронверкский проспект, 49, 197101, Санкт-Петербург, Россия; р.т.: +7(921)188-7946.

**Гусев Александр Алексеевич** — канд. техн. наук, ведущий инженер, научно-образовательная лаборатория «Техническое зрение», Университет ИТМО. Область научных интересов: машинное обучение, распознавание образов, статистическое обучение, распознавание статистических паттернов. Число научных публикаций — 32. gusew@internet.ru; Кронверкский проспект, 49, 197101, Санкт-Петербург, Россия; р.т.: +7(902)406-3854.

D. KRASNOV, M. VOLYNSKY, A. GUSEV  
**STATE ESTIMATION OF AN AGENT WITH STOCHASTIC  
DYNAMICS USING RECURRENT FILTERS**

*Krasnov D., Volynsky M., Gusev A. State Estimation of an Agent with Stochastic Dynamics Using Recurrent Filters.*

**Abstract.** The paper proposes a method for estimating the state vector of an agent in a multi-agent biological system based on noisy measurements using recurrent filters. It addresses the issues of scalability in existing approaches to monitoring the behavior of laboratory rodents and the absence of a unified mathematical framework. A mathematical description of an agent in the biological system is provided, along with the formulation of the task of estimating its state. The mathematical model is built upon a non-linear discrete-time system in state space. The solution to this problem is demonstrated using the example of skeletal keypoints in a Wistar rat, which are detected using a pre-trained detector. A fully connected neural network is proposed to parameterize the unknown dynamics of the system. The particle filter (a sequential Monte Carlo method) and the unscented Kalman filter were selected for a comparative analysis. The comparison of the methods was conducted on a collected and preprocessed dataset comprising images with a resolution of 1060×548 pixels and annotations of rat skeletal keypoints. The experimental results demonstrate the high efficacy of the proposed method and its advantage over an analytical description of the system's nonlinear dynamics. Among the compared methods, the dual estimation of both the state vector and the neural network parameters using two unscented Kalman filters achieved the minimal mean error of 6.4 pixels. However, for practical applications in real-time scenarios, a single filter employing a pre-trained neural network proves to be more advantageous. Moreover, the unscented Kalman filter in this case demonstrated higher accuracy than the particle filter (mean error of 8.1 pixels vs. 12.0 pixels). The results of this study can be used to solve the task of automated registration of Wistar rat behavior by parameterizing the functions that link state vectors with the output vectors of individual and group behavior.

**Keywords:** skeletal keypoints, laboratory animals, multi-agent biological system, unscented Kalman filter, particle filter, neural network, state vector estimation.

## References

1. Kuznetsov A. [The short review of multi-agent models]. *Upravlenie bol'shimi sistemami: sbornik trudov [Large-Scale Systems Control]*. 2018. no. 71(5). pp. 6–44. DOI: 10.25728/ubs.2018.71.1. (In Russ.).
2. Bernardi S., Scianna M. An agent-based approach for modelling collective dynamics in animal groups distinguishing individual speed and orientation. *Philosophical Transactions of the Royal Society B*. 2020. vol. 375. DOI: 10.1098/rstb.2019.0383.
3. Rashid M.M., Seyedi M., Jung S. Simulation of pedestrian interaction with autonomous vehicles via social force model. *Simulation Modelling Practice and Theory*. 2024. vol. 132. DOI: 10.1016/j.simpat.2024.102901.
4. Antonelli G. Interconnected dynamic systems: An overview on distributed control. *IEEE Control Systems Magazine*. 2013. vol. 33. no. 1. pp. 76–88. DOI: 10.1109/MCS.2012.2225929.
5. Proskurnikov A.V., Fradkov A.L. Problems and methods of network control. *Autom Remote Control*. 2016. vol. 77. pp. 1711–1740. DOI: 10.1134/S0005117916100015.

6. Xue Y., Chen W. Multi-Agent Deep Reinforcement Learning for UAVs Navigation in Unknown Complex Environment. *IEEE Transactions on Intelligent Vehicles*. 2024. vol. 9. no. 1. pp. 2290–2303. DOI: 10.1109/TIV.2023.3298292.
7. Zhao X., Yang R., Zhong L., Hou Z. Multi-UAV Path Planning and Following Based on Multi-Agent Reinforcement Learning. *Drones*. 2024. vol. 8. no. 1. DOI: 10.3390/drones8010018.
8. Shi H., Zhao Z., Chen J., Zhou M., Liu Y. Enhancing Unmanned Aerial Vehicle Path Planning in Multi-Agent Reinforcement Learning through Adaptive Dimensionality Reduction. *Drones*. 2024. vol. 8. no. 10. DOI: 10.3390/drones8100521.
9. Podelenyuk, P., Epifantsev I. Modeling the Formation of a Multi-Agent System as a System of Points of a Rigid. *IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*. 2021. pp. 594–597. DOI: 10.1109/ElConRus51938.2021.9396179.
10. Cong Y., Feng Z., Song H., Wang S. Containment control of singular heterogeneous multi-agent systems. *Journal of the Franklin Institute*. 2018. vol. 355. no. 11. pp. 4629–4643. DOI: 10.1016/j.jfranklin.2018.04.009.
11. Thummalapeda M., Liu Y.-C. Survey of containment control in multi-agent systems: concepts, communication, dynamics, and controller design. *International Journal of Systems Science*. 2023. vol. 54. no. 14. pp. 2809–2835.
12. Luo R., Peng Z., Hu J. On Model Identification Based Optimal Control and its Applications to Multi-Agent Learning and Control. *Mathematics*. 2023. vol. 11. no. 4. DOI: 10.3390/math11040906.
13. Iarosh D., Reneva G., Kornilova A., Konovalov P. Multiagent System of Mobile Robots for Robotic Football. *26th Saint Petersburg International Conference on Integrated Navigation Systems (ICINS)*. 2019. pp. 1–3. DOI: 10.23919/ICINS.2019.8769365.
14. Ribeiro A.F.A., Lopes A.C.C., Ribeiro T.A., Pereira N.S.S.M., Lopes G.T., Ribeiro A.F.M. Probability-Based Strategy for a Football Multi-Agent Autonomous Robot System. *Robotics*. 2024. vol. 13. no. 1. DOI: 10.3390/robotics13010005.
15. Dewantara B.S.B., Ariyadi B.N.D. Adaptive Behavior Control for Robot Soccer Navigation Using Fuzzy-based Social Force Model. *Smart Science*. 2021. vol. 9. no. 1. pp. 14–29. DOI: 10.1080/23080477.2021.1871799.
16. Du Z., Negenborn R.R., Reppa V. Cooperative Multi-Agent Control for Autonomous Ship Towing Under Environmental Disturbances. *IEEE/CAA Journal of Automatica Sinica*. 2021. vol. 8. no. 8. pp. 1365–1379. DOI: 10.1109/JAS.2021.1004078.
17. Bonnet F., Gribovskiy A., Halloy J., Mondada F. Closed-loop interactions between a shoal of zebrafish and a group of robotic fish in a circular corridor. *Swarm Intelligence*. 2018. vol. 12. no. 3. pp. 227–244. DOI: 10.1007/s11721-017-0153-6.
18. Kim C., Ruberto T., Phamduy P., Porfiri M. Closed-loop control of zebrafish behaviour in three dimensions using a robotic stimulus. *Scientific Reports*. 2018. vol. 8. no. 1. DOI: 10.1038/s41598-017-19083-2.
19. Kopman V., Laut J., Polverino G., Porfiri M. Closed-loop control of zebrafish response using a bioinspired robotic-fish in a preference test. *Journal of The Royal Society Interface*. 2013. vol. 10. no. 78. DOI: 10.1098/rsif.2012.0540.
20. Swain D.T., Couzin I.D., Ehrlich Leonard N. Real-Time Feedback-Controlled Robotic Fish for Behavioral Experiments with Fish Schools. *Proceedings of the IEEE*. 2012. vol. 100. no. 1. pp. 150–163. DOI: 10.1109/JPROC.2011.2165449.
21. Landgraf T., Bierbach D., Nguyen H., Muggelberg N., Romanczuk P., Krause J. RoboFish: increased acceptance of interactive robotic fish with realistic eyes and natural motion patterns by live Trinidadian guppies. *Bioinspiration & Biomimetics*. 2016. vol. 11. no. 1. DOI: 10.1088/1748-3190/11/1/015001.

22. Collignon B., Séguret A., Halloy J. A stochastic vision-based model inspired by zebrafish collective behaviour in heterogeneous environments. *Royal Society Open Science*. 2016. vol. 3. no. 1. DOI: 10.1098/rsos.150473.
23. Mwafo V., Anderson R.P., Butail S., Porfiri M. A jump persistent turning walker to model zebrafish locomotion. *Journal of The Royal Society Interface*. 2015. vol. 12. no. 102. DOI: 10.1098/rsif.2014.0884.
24. Zienkiewicz A.K., Ladu F., Barton D.A.W. Data-driven modelling of social forces and collective behaviour in zebrafish. *Journal of Theoretical Biology*. 2018. vol. 443. pp. 39–51. DOI: 10.1016/j.jtbi.2018.01.011.
25. Tuqan M., Porfiri M. Mathematical Modeling of Zebrafish Social Behavior in Response to Acute Caffeine Administration. *Frontiers in Applied Mathematics and Statistics*. 2021. vol. 7. DOI: 10.3389/fams.2021.751351.
26. van Dam E.A., Noldus L.P.J.J., van Gerven M.A.J. Deep learning improves automated rodent behavior recognition within a specific experimental setup. *Journal of Neuroscience Methods*. 2020. vol. 332. DOI: 10.1016/j.jneumeth.2019.108536.
27. Grieco F., Bernstein B.J., Biemans B. et al. Measuring Behavior in the Home Cage: Study Design, Applications, Challenges, and Perspectives. *Frontiers in Behavioral Neuroscience*. 2021. vol. 15. DOI: 10.3389/fnbeh.2021.735387.
28. Segalin C., Williams J., Karigo T. et al. The Mouse Action Recognition System (MARS) software pipeline for automated analysis of social behaviors in mice. *eLife*. 2021. vol. 10. DOI: 10.7554/eLife.63720.
29. Hsu A.I., Yttri E.A. B-SOId, an open-source unsupervised algorithm for identification and fast prediction of behaviors. *Nature Communications*. 2021. vol. 12. DOI: 10.1038/s41467-021-25420-x.
30. Ru Z., Duan F. Hierarchical Spatial-Temporal Window Transformer for Pose-Based Rodent Behavior Recognition. *IEEE Transactions on Instrumentation and Measurement*. 2024. vol. 73. pp. 1–14. DOI: 10.1109/TIM.2024.3379081.
31. Weinreb C., Pearl J.E., Lin S. et al. Keypoint-MoSeq: parsing behavior by linking point tracking to pose dynamics. *Nature Methods*. 2024. vol. 21. pp. 1329–1339. DOI: 10.1038/s41592-024-02318-2.
32. Donnarumma F., Preveze R., Maisto D. et al. A framework to identify structured behavioral patterns within rodent spatial trajectories. *Scientific Reports*. 2021. vol. 11. DOI: 10.1038/s41598-020-79744-7.
33. van Dam E.A., Noldus L.P.J.J., van Gerven M.A.J. Disentangling rodent behaviors to improve automated behavior recognition. *Front. Neurosci.* 2023. vol. 17. DOI: 10.3389/fnins.2023.1198209.
34. Krasnov D.I., Volynsky M.A., Gusev A.A. [Preprocessing of skeletal keypoints trajectories in the task of laboratory animal behavior recording automation]. *Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2025. vol. 25. no. 2. pp. 295–302. (In Russ.).
35. Buizza C., Fischer T., Demiris Y. Real-Time Multi-Person Pose Tracking using Data Assimilation. *IEEE Winter Conference on Applications of Computer Vision (WACV)*. 2020. pp. 438–447. DOI: 10.1109/WACV45572.2020.9093442.
36. Svensson D. Derivation of the discrete-time constant turn rate and acceleration motion model. *Sensor Data Fusion: Trends, Solutions, Applications (SDF)*. 2019. pp. 1–5. DOI: 10.1109/SDF.2019.8916654.
37. Yuan H., Han Y., Zhou Y. et al. State of Charge Dual Estimation of a Li-ion Battery Based on Variable Forgetting Factor Recursive Least Square and Multi-Innovation Unscented Kalman Filter Algorithm. *Energies*. 2022. vol. 15. no. 4. DOI: 10.3390/en15041529.

38. Huang J., Zhu Z., Guo F., Huang G. The Devil Is in the Details: Delving into Unbiased Data Processing for Human Pose Estimation. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. pp. 5699–5708. DOI: 10.1109/CVPR42600.2020.00574.
39. Lyu C., Zhang W., Huang H. et al. RTMDet: An Empirical Study of Designing Real-Time Object Detectors. 2024. arXiv preprint arXiv:2212.07784.
40. Wan E. A., Van Der Merwe R. The unscented Kalman filter for nonlinear estimation. Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No.00EX373). 2000. pp. 153–158. DOI: 10.1109/ASSPCC.2000.882463.
41. Volynsky M.A., Gurov I.P., Skakov P.S. [The recurrent algorithm for interferometric signals processing based on multi-cloud prediction model]. Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki –Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2014. vol. 14. no. 4. pp. 18–22. (In Russ.).

**Krasnov Dmitrii** — Ph.D. student, Technical vision laboratory, ITMO University. Research interests: computer vision, pattern recognition, image processing, artificial intelligence, deep learning. The number of publications — 7. dmitriy\_krasnov@outlook.com; 49, Kronverksky Av., 197101, St. Petersburg, Russia; office phone: +7(996)189-3418.

**Volynsky Maxim** — Ph.D., Associate Professor, Director, Technical vision laboratory, ITMO University. Research interests: computational photonics, biophotonics, interaction of optical radiation with matter, stochastic processing of quasi-periodic signals. The number of publications — 130. maxim.volynsky@gmail.com; 49, Kronverksky Av., 197101, St. Petersburg, Russia; office phone: +7(921)188-7946.

**Gusev Alexandr** — Ph.D., Lead engineer, Technical vision laboratory, ITMO University. Research interests: machine learning, pattern recognition, statistical learning, statistical pattern recognition. The number of publications — 32. gusew@internet.ru; 49, Kronverksky Av., 197101, St. Petersburg, Russia; office phone: +7(902)406-3854.