

Анализ и повышение качества изображений: общие методы и биомедицинские приложения

Крылов А.С. ^{a,*}, Насонов А.В. ^{b,**}, Сорокин Д.В. ^{c,***}, Хвостиков А.В. ^{d,****},
Павельева Е.А. ^{e,*****}, Пчелинцев Я.А. ^{f,*****}

^{a,b,c,d,e,f} Лаборатория математических методов обработки изображений,
Факультет вычислительной математики и кибернетики,
Московский государственный университет имени М.В. Ломоносова
119991, Москва, Ленинские горы, д.1, стр. 52

* e-mail: kryl@cs.msu.ru

** e-mail: nasonov@cs.msu.ru

*** e-mail: dsorokin@cs.msu.ru

**** e-mail: khvostikov@cs.msu.ru

***** e-mail: pavelyeva@cs.msu.ru

***** e-mail: yapchelintsev@live.cs.msu.ru

Аннотация

Рассмотрены общие методы обработки, анализа и повышения качества изображений и их биомедицинские приложения, разработанные участниками научной школы Лаборатории математических методов обработки изображений Факультета вычислительной математики и кибернетики Московского государственного университета имени М.В. Ломоносова. Описаны предложенные общие методы и алгоритмы повышения качества изображения при повышении разрешения и суперразрешения изображений, уменьшения артефактов колебаний Гиббса, повышения резкости изображений, подавления шумов на изображениях и совмещения изображений. Представлены методы анализа изображений, основанные на проекционном методе Эрмита, использовании функций Гаусса-Лагерра и использовании фазовой информации. Описаны и рассмотрены разработанные методы решения задач обработки и анализа медицинских изображений в том числе для задач гистологии, цветного доплеровского картирования потока, ультразвуковой диагностики фиброза печени, КТ- перфузии головного мозга, диагностики болезни Альцгеймера, дерматологии, анализа рентгеновских изображений грудной клетки, совмещения, отслеживания,

сегментации и синтеза изображений живых клеток. В статье проиллюстрирована основная исследовательская идея эффективности гибридного подхода при совместном использовании классических математических методов и подходов глубокого обучения.

ключевые слова: анализ изображений, обработка изображений, повышение качества изображений, медицинские изображения, изображения клеточной микроскопии, математические методы, сверточные нейронные сети, гибридные методы.

1 ВВЕДЕНИЕ

В статье рассматриваются наиболее интересные общие задачи обработки, анализа и повышения качества изображений и их приложения в биомедицине, которые были предметом исследований в лаборатории математических методов обработки изображений факультета вычислительной математики и кибернетики Московского государственного университета имени М.В. Ломоносова. Представлены методы и алгоритмы, разработанные участниками школы при решении этих задач. В этом году лаборатория отмечает свое 15-летие, но ее корни уходят в традиции научной школы выдающегося математика и основателя факультета вычислительной математики и кибернетики Андрея Николаевича Тихонова.

Структура документа выглядит следующим образом. В Разделе 2 описываются работы по оценке и повышению качества изображений. Рассмотрены задачи повышения разрешения изображений и подавления различных артефактов. Метод, основанный на использовании функций Эрмита, и его применения к различным задачам анализа изображений представлены в Разделе 3. В Разделе 4 представлены задачи и алгоритмы для различных биомедицинских приложений. Краткое Заключение завершает статью.

2 ПОВЫШЕНИЕ И ОЦЕНКА КАЧЕСТВА ИЗОБРАЖЕНИЙ

Целью улучшения изображения является его обработка таким образом, чтобы результат был более подходящим для конкретного приложения, чем исходное изображение. Это особенно важно в биомедицине, когда невозможно получать изображения необходимого качества.

2.1 Ресамплинг изображений и суперразрешение

Для повышения разрешения изображения был разработан ряд алгоритмов. Он включает в себя как однокадровые, так и многокадровые алгоритмы.

2.1.1 Однокадровое суперразрешение

Для решения проблемы повышения разрешения изображения, также известной как ресамплинг или как однокадровое суперразрешение, исследование проводилось в двух направлениях. В первом из них рассмотрена классическая математическая модель ресамплинга изображений. Задача была поставлена как обратная задача для модели уменьшения масштаба изображения. Метод регуляризации Тихонова со стабилизатором полной вариации [56] был использован для решения этой некорректно поставленной задачи:

$$z_{\alpha} = \arg \min_z (\|Az - u\|_2^2 + \alpha TV[z]),$$

где u — заданное изображение низкого разрешения, A — оператор понижения разрешения, $TV [z]$ — стабилизатор в виде функционала полной вариации, а α — параметр регуляризации. Функционал полной вариации работает как априорное знание об изображении.

Результат во многом зависит от выбора параметра регуляризации. В [77] была установлена связь между значениями полной вариации соответствующих изображений низкого и высокого разрешения и предложена явная схема выбора параметра регуляризации.

Второе направление было основано на подходе машинного обучения, в частности на сверточных нейронных сетях. Вместо того, чтобы разрабатывать новые модели сверточных нейронных сетей, мы сосредоточились на улучшении существующих алгоритмов. Правильная подготовка данных так же важна, как и хорошая нейросетевая модель. В [68] предложен способ построения обучающего набора данных для задачи ресамплинга изображения с зашумленными входными данными. В [46] исследовано применение сверточных нейронных сетей для масштабирования изображений сетчатки глаза. В [69] было показано, что применение метода анализа нулевых компонент помогает достичь лучших результатов на контурах и текстурированных участках.

Мы также разработали несколько алгоритмов ресамплинга изображений с адаптивными весами, учитывающими направления контуров, которые выбираются в соответствии с локальными особенностями градиента, и интерполяционными ядрами, которые определяются с использованием пар изображений низкого и высокого разрешения для целевого класса [76, 79].

2.1.2 Многокадровое суперразрешение

Многокадровое суперразрешение представляет собой реконструкцию одного изображения высокого разрешения из нескольких наблюдений низкого разрешения. В отличие от однокадрового суперразрешения, объем доступных данных гораздо более информативный, и нет необходимости использовать априорную информацию для реконструкции изображения высокого разрешения. При этом используется

классический подход, основанный на модели уменьшения разрешения изображения. Она описывается как система уравнений: найти изображение высокого разрешения, которое дает наблюдения низкого разрешения после применения операторов движения и понижения разрешения, и задача суперразрешения часто формулируется как задача минимизации, аналогичная задаче однокадрового ресамплинга:

$$z_\alpha = \arg \min_z \left(\sum_{k=1}^K \|AF_k z - u_k\|_2^2 + \alpha TV[z] \right),$$

где u_k — K входных изображений низкого разрешения, F_k — соответствующие операторы движения.

Наиболее сложными задачами становятся минимизация функционала и нахождение операторов движения F_k , которые представляют собой соответствие между координатами пикселей изображений низкого разрешения с субпиксельной точностью (эта задача называется оценкой оптического потока). Наше исследование было сосредоточено на разработке алгоритмов для вычислительно эффективной неитеративной реконструкции из серии изображений и видеопоследовательностей.

В [49] мы рассмотрели задачу нахождения оптического потока при изменении освещенности между кадрами. Мы предложили модификацию алгоритма Канаде-Лукаса, основанную на использовании частных производных интенсивности изображения. В [50] был предложен неитеративный алгоритм решения обратной задачи. Идея состояла в том, чтобы адаптивно найти ядро обратной свертки, используя свойство самоподобия, и использовать его для непосредственного поиска изображения высокого разрешения.

В [73] был предложен взвешенный медианный фильтр для неитеративной реконструкции изображения высокого разрешения. Пиксели из изображений низкого

разрешения были отображены на сетку высокого разрешения, затем была выполнена интерполяция с использованием взвешенной медианы с весами Гаусса. Такой подход значительно улучшил результаты для шумных изображений и изображений с ошибочно оцененным движением.

На Рис. 1 показаны результаты для предложенных алгоритмов суперразрешения.



а) Изображения низкого разрешения



б) Интерполяция методом ближайшего соседа



с) Ресамплинг одного изображения с использованием регуляризации полной вариации [56]



д) Многокадровое суперразрешение с использованием быстрой деконволюции и взвешенной медианной фильтрации [73]



е) Многокадровое суперразрешение высокого качества

Рис. 1 Пример результатов суперразрешения предложенных алгоритмов для реальной последовательности изображений. 16 изображений низкого разрешения были использованы для реконструкции изображения высокого разрешения с повышением разрешения в 2 раза

2.2 Артефакты ложного оконтуривания

Обнаружение и подавление колебаний Гиббса на изображении (артефактов ложного оконтуривания, также известных как рингинг) было одной из главных тем наших исследований на протяжении многих лет. Артефакт рингинга вызван повреждением

или потерей высокочастотной информации. Он проявляется в виде волн или колебаний вблизи сильных контуров. Наиболее известными примерами являются его появление в изображениях МРТ, в различных методах улучшения изображения (устранения размытия, повышение резкости, повышение разрешения и т.д.), при сжатии алгоритмом JPEG2000. Мы начали с разработки классических математических методов подавления рингинга (регуляризации полной вариации) и оценки уровня рингинга методом анализа профилей контуров [42, 70, 71, 107], и их использования для адаптивного устранения размытия изображения, и комбинированного метода линейного ресамплинга с контролем рингинга [43, 45] и для получения медицинских изображений МРТ [130].

Позже были разработаны различные методы обнаружения рингинга и методы дерингинга изображения, основанные на использовании разреженных представлений [122, 123, 124]. Алгоритмы обнаружения и подавления рингинга были основаны на построении синтетического словаря, который представляет эффект рингинга как сумму размытых контуров и непосредственно колебательной компоненты. Мы сравнили методы совместной настройки словарей, а также отдельной настройки словарей для естественных изображений и изображений чистой колебательной компоненты. Было обнаружено, что первый подход больше подходит для низкого уровня рингинга, в то время как сильный рингинг лучше подавлялся методом отдельного обучения.

Последние годы мы работали над гибридным методом дерингинга [96, 97], основанным на совместном использовании классических методов и глубокого обучения.

2.3 Повышение резкости методом деформирования сетки

Устранение размытия изображений было одной из сложных проблем обработки изображений в течение длительного времени. Проблема в том, что ядро размытия и

информация о типе и уровне шума неизвестны и должны быть оценены. Неравномерность размытия поля изображения, ошибки в определении ядра размытия и шума негативно влияют на качество алгоритмов устранения размытия изображений.

Мы предложили подход повышения резкости контуров, основанный на алгоритме деформации сетки пикселей, который делает переходные участки контуров тоньше без их искажения (см. Рис. 2) [84]. По сравнению с классическим подходом к устранению размытия изображения, подход с деформацией сетки пикселей не изменяет уровень шума, не вводит артефакт рингинга и не нуждается в ядре размытия. Вместо этого ему нужен только приблизительный уровень размытия изображения.



Рис. 2 Идея повышения резкости контуров изображения методом деформации сетки

Поскольку повышение резкости путем деформации сетки влияет только на контуры, сохраняя текстурированные области нетронутыми, лучшим сценарием является использование предлагаемого алгоритма деформации сетки в качестве этапа постобработки после существующих алгоритмов улучшения изображения [47, 51, 82]. Пример показан на Рис. 3.

В [81] для задачи выбора параметров алгоритма деформации сетки предложен точный и устойчивый метод оценки ширины контура, основанный на модели Гауссовского

контура и анализе нерезкого маскирования. Вычислительно эффективная реализация предложенного алгоритма представлена в [19]. В [78] предложен метод выбора параметров алгоритма деформации сетки сверточной нейронной сетью. В [44, 48] представлена объемная реализация предложенного алгоритма. Усовершенствование алгоритма деформации сетки в угловых областях представлено в [75].



Рис. 3 Пример применения предложенного алгоритма деформации сетки пикселей в качестве стадии постобработки после устранения размытия изображения

Программная реализация предложенного алгоритма доступна на сайте авторов <https://imaging.cs.msu.ru/en/soft>.

2.4 Подавление шумов на изображениях

По-прежнему верно, что подавление шумов на изображениях является сложной задачей для исследователей. Шумоподавление является важной проблемой в различных областях применения, где необходимо удалять шумовые компоненты, сохраняя в то же время полезную информацию. Общие подходы шумоподавления для изображений, обычно основаны на предположении, что шум является аддитивным белым гауссовским шумом (АБГШ). Тем не менее, во многих приложениях, таких как КТ, ультразвуковая диагностика и т.д., существуют специальные типы шума и даже комбинации различных типов шума.

В [117] сотрудниками нашей лаборатории были представлены два метода шумоподавления на КТ-изображениях: 3D-расширение алгоритмов быстрого ранжирования (Rank-2.5D) и 3D-расширение алгоритма нелокальных средних (NLM-2.5D). Также были разработаны алгоритмы шумоподавления изображений с использованием локального проекционного метода Эрмита [61, 62]. В [74] предложено усовершенствование алгоритма шумоподавления и устранения размытия изображений VM3D с использованием обобщенной полной вариацией. Предложен способ построения изображения с низким уровнем шума из последовательности множественных зашумленных изображений с использованием взвешенной минимизации ядерной нормы [83].

Многие из существующих современных методов шумоподавления изображений для АБГШ основаны на сверточных нейронных сетях (СНС). Во многих случаях они дают лучшие результаты, чем классические математические методы, основанные на использовании априорной информации. Тем не менее, нельзя полностью полагаться только на методы, основанные на СНС. Их результаты сильно зависят от используемого набора обучающих данных, и даже небольшие различия во входных данных могут привести к непредсказуемому нарушению на выходе. Для борьбы с возможной практической нестабильностью методов на основе СНС были предложены новые гибридные методы шумоподавления, которые включали некоторые комбинации методов на основе СНС и классических методов шумоподавления. Эти комбинации методов могут дать лучшие результаты, но тем не менее возникают дополнительные проблемы. Наряду с высоким уровнем неопределенности выбора гиперпараметров СНС существует также неопределенность в выборе параметров классических методов. Таким образом, необходима безреференсная автоматическая оценка параметров

классических методов фильтрации. Для решения этой проблемы мы предложили многомасштабный метод автоматического выбора параметров шумоподавления. Оптимизация параметров производится на участках с хребтовыми структурами, когда можно проанализировать их внешний вид на разнице между исходным шумным и отфильтрованным изображением (так называемом изображении шума метода). Если это разностное изображение носит характер случайного шума, то фильтрация может быть усилена. Если на разностном изображении метода появляются регулярные компоненты, то сила фильтрации слишком велика. Для анализа мы используем взаимную информацию, тесно связанную с условной энтропией, и рассматриваем изображения, искажённые гауссовским шумом с малым радиусом корреляции. Для оценки размеров и направлений деталей характеристик изображения используется подход, основанный на анализе собственных значений матрицы Гесса (см. Раздел 2.4.1).

Алгоритмы шумоподавления АБГШ с этим автоматическим выбором параметров были разработаны для методов NLM и LJNLM-LR [63], нелинейной диффузии [65], полной вариации [60], VM3D [64], Перона-Малика [80] и взвешенной ядерной нормы [125].

Гибридные методы шумоподавления АБГШ с использованием автоматического выбора классических алгоритмов были представлены в [37, 52].

Гибридный метод подавления пуассоновского шума был представлен в [21].

2.4.1 Многомасштабное обнаружение хребтовых структур изображения

Обнаружение хребтовых структур является ключевым моментом в упомянутых выше методах шумоподавления изображения.

Мы используем следующий алгоритм обнаружения хребтовых структур, основанный на идее, что лапласовский фильтр может указывать на наличие хребтовой структуры.

Определим:

$$L^\sigma(x, y) = \sigma^2 \cdot I(x, y) * G_\sigma(x, y),$$

$$G_\sigma(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}},$$

где $I(x, y)$ — интенсивность исходного изображения. Множитель σ^2 в формуле для $L^\sigma(x, y)$ используется для выравнивания отклика фильтрации оператором Лапласа на разных масштабах. Таким образом, если мы увеличим и изображение, и σ на один и тот же коэффициент, то отклик будет одинаковым для соответствующих точек. Отметим также, что дифференциация $L^\sigma(x, y)$ эквивалентна свертке исходного изображения $I(x, y)$ с соответствующей производной функции Гаусса. Пусть $L_{xx}^\sigma(x, y)$, $L_{xy}^\sigma(x, y)$, $L_{yy}^\sigma(x, y)$ являются вторыми производными $L^\sigma(x, y)$ по соответствующим переменным. Модуль лапласиана $\Delta L^\sigma(x, y)$ имеет максимум в центральной точке хребтовой структуры шириной 2σ . Чтобы найти направление хребтовой структуры, мы строим матрицу Гессе:

$$H^\sigma(x, y) = \begin{pmatrix} L_{xx}^\sigma(x, y) & L_{xy}^\sigma(x, y) \\ L_{xy}^\sigma(x, y) & L_{yy}^\sigma(x, y) \end{pmatrix}.$$

Тогда собственный вектор $\vec{v}^\sigma(x, y)$, соответствующий наименьшему собственному значению $H^\sigma(x, y)$, будет направлен вдоль хребтовой структуры. Для многомасштабного обнаружения хребтовых структур мы используем различные значения $\sigma \in \{\sigma_1, \dots, \sigma_n\}$, $\sigma_i = \sigma_0 \cdot \nu^{i-1}$. Вычисляя $\Delta L^{\sigma_i}(x, y)$ и $\vec{v}^{\sigma_i}(x, y)$, соответствующие σ_i , находим характерный размер хребтовой структуры $s(x, y)$ и направление $\vec{v}(x, y)$ как:

$$s(x, y) = \arg \max_{\sigma_i} (|\Delta L^{\sigma_i}(x, y)|),$$

$$\vec{v}(x, y) = \vec{v}^{s(x, y)}(x, y).$$

Подход к обнаружению цветных хребтовых структур был предложен в [22]. Также было установлено, что использование анизотропной диффузии в многомасштабном методе обнаружения хребтовых структур существенно улучшило качество обнаружения хребтовых структур [59].

Предложены гибридные методы, основанные на сверточных нейронных сетях и многомасштабном детектировании хребтовых структур, для сегментации биометрических изображений [102, 121] и для матирования изображений человека [104].

2.5 Совмещение Изображений

Задачи совмещения изображений очень актуальны для общих проблем анализа изображений и возникают во многих биомедицинских приложениях. Наши конкретные алгоритмы совмещения изображений в гистологии (см. Раздел 4.1) и анализе изображений клеток (см. Раздел 4.8.2) описаны ниже.

В то же время мы работали над общим ускорением методов жесткого совмещения. В [119] было предложено итеративное исключение сильно несоответствующих контурных точек с последующим исправлением параметров для остальных точек. Здесь особая структура гистологических изображений, содержащих срезы желез эллиптической формы, позволила находить соответствующие эллипсы на неподвижных и движущихся изображениях.

Выполнен ряд работ по оценке оптимального коэффициента понижения разрешения изображения для ускорения метода максимизации взаимной энтропии для жесткого совмещения. В алгоритме оценки использован анализ зависимости параметров

быстрого двумерного метода декомпозиции по эмпирическим модам от масштабирования [17, 18, 36, 106].

2.6 Оценка Качества Изображения

Алгоритмы оценки качества изображения обычно выдают одно значение, представляющее качество изображения. Но это значение не объясняет, почему одно изображение лучше другого. Общими факторами, влияющими на качество изображения, являются недостаточная реконструкция изображения или появление артефактов, таких как эффект рингинга, размытие или усиление шума. Анализ артефактов изображения может помочь улучшить оценку качества изображения.

Мы предложили способ находить области изображения, где могут появиться типичные артефакты алгоритмов улучшения изображения. Мы ввели понятие *основных контуров* — резких и сильных контуров, удаленных от других контуров [72].

Выделяются две области вблизи основных контуров: ПОК (профиль основного контура) — это область, включающая в себя сам основной контур с небольшой окрестность до $1/2$ ширины контура, и ООК (окрестность основного контура) — область на расстоянии от $1/2$ до 2 ширин контуров от основного контура. Область ПОК используется для анализа эффекта размытия, в то время как область ООК используется для обнаружения эффекта рингинга.

Предложенный алгоритм проиллюстрирован Рис. 4. Он состоит из следующих этапов:

1. Обнаружение контуров методом Канны с нулевыми пороговыми значениями и параметром масштаба σ , соответствующим ожидаемому размеру артефакта.

2. Маскирование контуров: маскированными считаются контуры с величиной градиента менее $1/2$ его величины у окружающих контуров. Такие контуры обычно относятся к текстурам изображения и не подходят для анализа артефактов.
3. Поиск основных контуров: немаскированные контуры, удаленные от других немаскированных контуров.
4. Поиск областей ПОК и ООК.




а) Входное изображение




б) Обнаружение контуров + карта масок контуров

Маскированные контуры обозначены синим цветом



с) Основные контуры (белый цвет) и неосновные контуры (красный цвет)



д) Области ПОК (белые области) и ООК (серые области)

Рис. 4 Иллюстрация алгоритма определения окрестностей основных контуров

Программная реализация предложенного алгоритма доступна на сайте авторов <https://imaging.cs.msu.ru/en/soft>.

В [109] мы предложили метрику качества изображения, основанную на основных контурах и проекционном методе Гаусса-Лагерра (подробности см. в разделе 3.2). Мы определили модульную метрику согласованности угловых контуров, которая вычисляется в областях ПОК и ООК изображения. Предложенная метрика была применена в задаче повышения резкости изображения.

В [13] мы также ввели метрику, основанную на модифицированном индексе структурного сходства, для улучшения алгоритма подавления шума на изображениях методом нелокального среднего. Продемонстрирован потенциал этой метрики с физически обоснованной весовой функцией для каждого компонента.

3 АНАЛИЗ ИЗОБРАЖЕНИЙ

3.1 Проекционный Метод Эрмита

Выбор функций Эрмита для анализа сигналов и изображений не случаен. При изучении и решении операторных уравнений математической физики (формально запишем такое уравнение как $Az = u$) и особенно при решении обратных задач для этих уравнений, в собственных функциях оператора A (или оператора A^*A в случае несамосопряженного оператора) для рассматриваемого выбора пространства функций содержится много информации, соответствующей физике изучаемых явлений. Это определяет использование функций Эрмита, являющихся собственными функциями преобразования Фурье из $L_2(\mathbb{R})$ в $L_2(\mathbb{R})$, в методах обработки и анализа сигналов, поскольку во многих случаях эти методы основаны на использовании преобразования Фурье. Более того, само определение преобразования Фурье из $L_2(\mathbb{R})$ в $L_2(\mathbb{R})$

классических книгах Норберта Винера и Эдварда Титчмарша дано с использованием функций Эрмита.

Технически, ортонормированные в $L_2(\mathbb{R})$ функции Эрмита $\psi_k(x)$ могут быть вычислены как

$$\begin{aligned}\psi_0(x) &= \frac{1}{\sqrt[4]{\pi}} e^{-x^2/2}, \\ \psi_1(x) &= \frac{\sqrt{2}x}{\sqrt[4]{\pi}} e^{-x^2/2}, \\ \psi_n(x) &= x \sqrt{\frac{2}{n}} \psi_{n-1}(x) - \sqrt{\frac{n-1}{n}} \psi_{n-2}(x).\end{aligned}$$

Они также могут быть определены с помощью производных функции Гаусса. Примеры графиков ортонормированных функций Эрмита приведены на Рис. 5-7.




Рис. 5 Функция ψ_0




Рис. 6 Функция ψ_4




Рис. 7 Функция ψ_{29}

Отметим, что сходство поведения внутренних колебаний функций Эрмита с поведением тригонометрических функций не случайно. Асимптотически значения функций Эрмита стремятся к функциям $\cos(x)$ и $\sin(x)$ в зависимости от четности индекса.

Для случая «симметричного» преобразования Фурье, определяемого как

$$\mathfrak{F}f = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} f(x) e^{-i\lambda x} dx,$$

выполняется следующее уравнение

$$\mathfrak{F}\psi_n = (-i)^n \psi_n.$$

Таким образом, и функции ψ_n , и их преобразования Фурье $\mathcal{F}\psi_n$ одинаково вычислительно локализованы в пространственной и частотной областях.

Вообще говоря, разложение в ряд по функциям Эрмита (проекционный метод Эрмита) дает альтернативу понятию «частота». И эти функции являются «временно-частотно» вычислительно локализованными, в отличие от не локализованных в пространстве тригонометрических функций. Поэтому проекционный метод Эрмита является хорошим кандидатом для замены дискретного преобразования Фурье в задачах обработки и анализа сигналов разных размерностей.

Двумерные ортонормированные в $L_2(\mathbb{R}^2)$ функции Эрмита $\psi_{n,m}$ определяются через одномерные функции как

$$\psi_{n,m}(x, y) = \psi_n(x)\psi_m(y).$$

Примеры графиков двумерных ортонормированных функций Эрмита $\psi_{n,m}$ показаны на Рис. 8 и Рис. 9.




Рис. 8 Функция $\psi_{0,0}$




Рис. 9 Функция $\psi_{2,2}$

Под проекционным методом Эрмита мы подразумеваем разложение функции в ряд Фурье по функциям Эрмита

$$f(x) = \sum_{k=0}^N c_k \psi_k(x),$$

где $\psi_k(x)$ — одномерные ортонормированные функции Эрмита в $L_2(\mathbb{R})$, c_k — коэффициенты Эрмита:

$$c_k = \int_{-A}^A f(x)\psi_k(x)dx.$$

Для фиксированного N предел A определяется таким образом, что все функции ψ_k , $k \leq N$ вычислительно ортогональны друг другу. Таким образом, разложение является ортогональным с вычислительной точки зрения.

Идея проекционного метода Эрмита была введена в [41]. Метод использовался для анализа дифракционных данных [6, 53] и в качестве замены дискретного преобразования Фурье для фильтрации изображений [39]. Затем он использовался для задач параметризации текстур [40], деблокинга изображений [67], поиска в базе изображений [35]. Быстрый проекционный метод Эрмита был представлен в [38].

В сотрудничестве с профессором Srdjan Stanković и профессором Irena Orović из Университета Черногории метод был применен в серии работ в области частотно-временного анализа [115, 116].

Функции Эрмита и проекционный метод Эрмита также использовались в биометрии для анализа изображений радужной оболочки глаза, для выделения [90] и сопоставления [87, 89] ключевых точек изображений радужной оболочки глаза.

В [91, 92] определена аппроксимация преобразования Фурье функции $f(x) = \sum_{k=0}^{\infty} c_k \psi_k(x)$ с использованием функций Эрмита (АПФЭ):

$$HF_{f,n}(x) = \sum_{k=0}^n c_k (-i)^k \psi_k(x),$$

и предложен синтез фазы и амплитуды АПФЭ различных изображений с использованием функций Эрмита. Доказана теорема о единственности восстановления сигнала с точностью до масштабного множителя по одной только фазе его АПФЭ. Также предложен алгоритм восстановления сигнала по фазе АПФЭ [89] (Рис. 10).

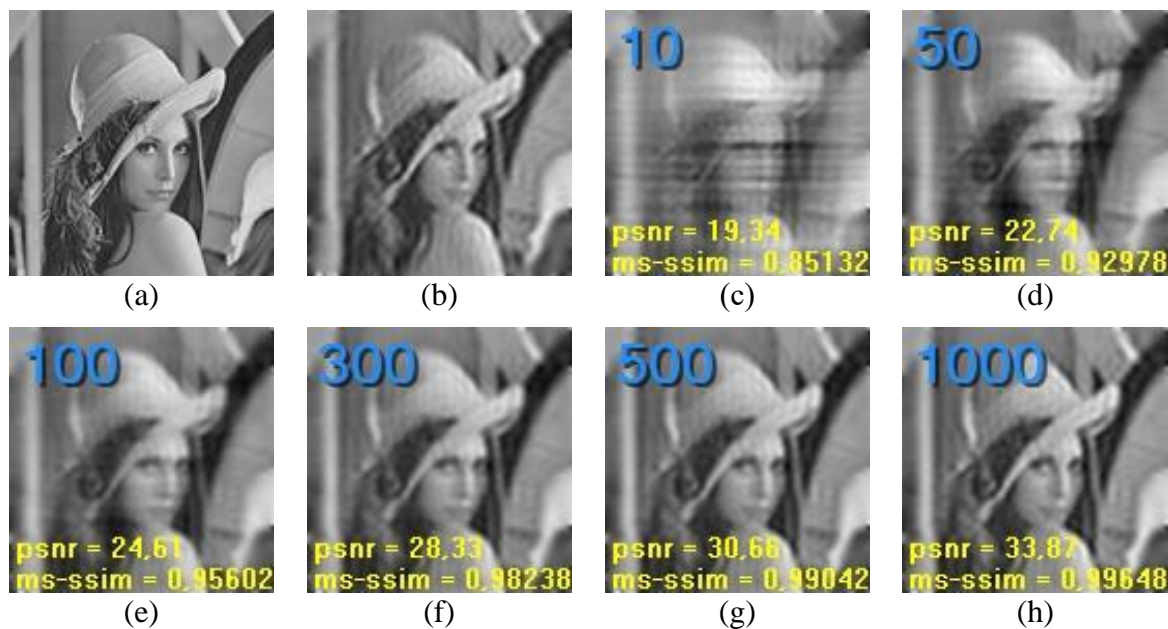


Рис. 10 Итерационный алгоритм восстановления изображения по фазе АПФЭ; изображение (b) является аппроксимацией изображения (a); (c)-(h) – результаты после различного числа итераций алгоритма

В [88] для сопоставления изображений была введена функция проекционной фазовой корреляции (НРРОС) на основе проекционного метода Эрмита. Если два изображения похожи, их НРРОС-функция имеет четкий пик, если же два изображения не похожи, то НРРОС-функция не имеет четкого пика. Преимущество НРРОС-функции особенно заметно при сопоставлении изображений небольших размеров, и был предложен метод сопоставления ключевых точек изображений радужной оболочки глаза с помощью НРРОС-функции.

3.2 Функции Гаусса-Лагерра Для Анализа Изображений

Рассмотрим семейство комплексных ортонормированных и сепарабельных в полярной системе координат (r, γ) функций:

$$\Psi_n^\alpha(r, \gamma; \sigma) = \psi_n^{|\alpha|}(r^2/\sigma) e^{i\alpha\gamma}.$$

Эти функции называются круговыми гармоническими функциями Гаусса-Лагерра (КГФ), определяются целыми числами $n = 0, 1, \dots$ (называемыми круговым порядком) и $\alpha = 0, \pm 1, \pm 2 \dots$ (называемыми угловым порядком), а их радиальные профили являются функциями Лагерра:

$$\psi_n^{|\alpha|}(x) = \frac{1}{\sqrt{n! \Gamma(n + \alpha + 1)}} x^{\alpha/2} e^{-x/2} L_n^\alpha(x), \quad L_n^\alpha(x) = (-1)^n x^{-\alpha} e^x \frac{d}{dx^n} (x^{n+\alpha} e^{-x}).$$

Действительная и мнимая части $\Psi_n^\alpha(r, \gamma)$ ($n = 0, 1, \dots, 4; \alpha = 1, 2, \dots, 5$) проиллюстрированы на Рис. 11.

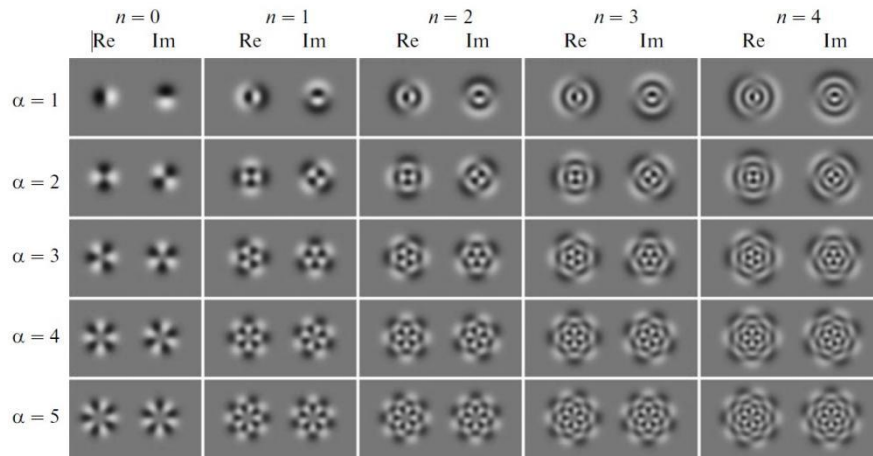


Рис. 11 Действительные и мнимые части Ψ_n^α ($n = 0, 1, \dots, 4; \alpha = 1, 2, \dots, 5$)

Используя КГФ Гаусса-Лагерра, мы разработали проекционный метод для построения локальных дескрипторов изображения и обнаружения ключевых точек. Метод

проекция был основан на локальном разложении изображения в ряд по КГФ Гаусса-Лагерра в окрестности ключевой точки [110]. Используя свойства этих функций и их связь с двумерными функциями Эрмита, мы значительно ускорили вычисление дескрипторов. Более того, мы предложили специальный численный метод для снижения вычислительной сложности предложенных методов проекции [111]. Предложенный подход продемонстрировал свою эффективность по сравнению с дескрипторами SIFT в задаче оценки матрицы гомографии для нескольких изображений, полученных с разных точек. Метод был дополнительно обобщен для использования с цветными изображениями [54], где мы предложили использовать специальную форму градиента цветного изображения для дифференциальных операций с цветными изображениями вместо преобразования их в оттенки серого. Такой подход продемонстрировал, что использование цветовой информации для построения дескрипторов ключевых точек для определения ключевых точек как в цвете, так и в оттенках серого обычно повышает качество сопоставления изображений.

3.3 Фазовые Методы

Фаза часто содержит более важную информацию о сигнале, чем амплитуда. Как правило, используются понятия глобальной и локальной фазы. Глобальная фаза обычно означает фазу преобразования Фурье всего сигнала, а локальная фаза — это фаза локального преобразования (оконного преобразования Фурье, вейвлет-преобразования и т.д.).

Предложено два фазовых метода для сопоставления ключевых точек изображений, основанных на использовании информации о фазе в локальных окрестностях ключевых точек, и эти методы используются для сопоставления ключевых точек изображений радужной оболочки глаза. В первом методе вычисляется функция проекционной

фазовой корреляции (НРРОС) [88, 89]. Если ключевые точки взяты из одного и того же образца текстуры радужной оболочки, НРРОС-функция имеет четкий пик, в то время как в случае разных глаз НРРОС-функция не имеет четкого пика. Второй метод использует информацию о фазовой конгруэнтности в окрестности ключевых точек радужной оболочки для сопоставления изображений [99, 100].

4 БИОМЕДИЦИНСКИЕ ПРИЛОЖЕНИЯ

4.1 Гистология

Одной из наиболее динамично развивающихся областей медицины с широким спектром приложений для обработки изображений и компьютерного зрения является область гистологии, которая в последнее время благодаря широкому использованию сканеров нового поколения трансформировалась в цифровую патологию. Современные сканеры могут получать изображения всего стекла с образцом ткани, разрешение таких полнослайдовых изображений (англ. Whole Slide Images, WSI) может составлять 100 тыс.×100 тыс. пикселей и даже больше, размер этих изображений исчисляется гигабайтами.

Сложность и разнообразие гистологических структур открывают большое количество задач автоматического анализа изображений, включая сегментацию, совмещение, поиск по содержимому и многое другое. Из-за неоднородности гистологических структур практически невозможно анализировать эти изображения «классическими» математическими методами, поэтому мы сосредоточились на разработке методов глубокого обучения и гибридных методов.

Помимо использования существующих общедоступных наборов данных, мы создали собственный набор данных PATH-DT-MSU [27, 86], где в подмножестве S1 мы собрали

и проаннотировали гистологические изображения нормальных и открытых желез и предложили новую архитектуру СНС для сегментации желез. Более сложной задачей, актуальной для гистологов, является осуществление объектной сегментации желез. Нами разработан оригинальный гибридный метод обучаемых активных контуров [28], ключевой особенностью которого является глубокая интеграция классической модели активного контура и СНС.

В наших исследованиях мы также сосредоточились на проблеме сокращения времени, необходимого для разметки изображений, и разработали метод быстрой разметки биомедицинских изображений [29]. Этот гибридный метод объединяет модель К-ближайших соседей (KNN) с СНС и позволяет ускорить процесс сегментации желез до 10 раз.

Очевидной проблемой обработки WSI с помощью нейронных сетей является их очень высокое разрешение, которое негативно влияет на производительность. Процесс аннотирования WSI также занимает слишком много времени. С другой стороны, большим преимуществом работы с WSI является возможность просмотра всего изображения сразу и проведения анализа слоев ткани. Таким образом, самым простым способом сегментации WSI и идентификации слоев является подход сегментации через классификацию (Рис. 12), который мы использовали в [30].




Рис. 12 Визуализация сегментации через классификацию полнослайдового гистологического изображения с полупрозрачной цветовой маской. Различные цвета соответствуют различным типам тканей

Еще одной важной задачей WSI является совмещение изображений. В медицинской практике часто бывает необходимо совместно анализировать по-разному окрашенные гистологические срезы. Однако во время подготовки слайдов ткани подвергаются деформации, и совмещение изображений крайне необходимо. Важность задачи подтверждает международное соревнование по автоматическому нежесткому совмещению гистологических изображений (ANHIR), которое было организовано в рамках Международного симпозиума по биомедицинской визуализации в 2019 году [7], где мы принимали участие в подготовке наборов данных соревнования и разработке показателей оценки, а также работали с нашими коллегами из Чехии и Испании. Соревнование проходит до сих пор и доступно в интернете, и к моменту написания этой статьи было представлено 42 метода. Набор данных, собранный и размеченный во время подготовки, стал стандартным для оценки подходов к совмещению гистологических изображений. Используя набор данных ANHIR, мы разработали наш собственный аффинный подход к совмещению гистологических изображений [101]

(см. Рис. 13), который представляет собой метод обучения без подготовки (англ. zero-shot learning) на основе СНС, который на момент написания этой статьи превосходит конкурирующие методы аффинной регистрации.




Рис.13 Результаты аффинного совмещения. Исходное (a) и целевое (b) изображения показаны в желтой и фиолетовой цветовых шкалах соответственно для большей наглядности. Наложение несовмещенных изображений показано на (c), наложение результатов совмещения показано на (d).

Основными проблемами работы с WSI являются проблема передачи коллекций изображений между гистологами и наличие большого количества различных несовместимых форматов файлов. Для решения этих проблем мы разработали PathScribe (<https://pathscribe.ru>) — новый облачный мультиплатформенный программный инструмент для работы с полнослайдовыми гистологическими изображениями. С осени 2022 года PathScribe используется в образовательных целях на факультете фундаментальной медицины МГУ им. М.В. Ломоносова. PathScribe активно развивается как образовательный, так и научный инструмент.

Работа выполнена в сотрудничестве с профессором П.Г. Мальковым и И.А. Михайловым из Медицинского научно-исследовательского центра МГУ им. М.В. Ломоносова.

4.2 Цветное доплеровское картирование потока

Вычислительные задачи ультразвуковой диагностики сердца исследовались совместно с НИИЦ им. Петровского РАМН. Они включали построение трехмерной динамической модели левого сердечного желудочка [128] и ряд вычислительных методов для развертки данных изображения цветного доплеровского картирования потока. Разработаны методы, основанные на разрезе графа [127], и методы регуляризации [131]. Позднее для оптимизации алгоритмов было предложено межкадровое соединение [126]. Оригинальная комплексная фазовая предварительная фильтрация также использовалась для подавления артефакта ложного наложения спектров и улучшения результатов [129]. Дисперсии потока использовалась в качестве весовых коэффициентов при минимизации функции энергии. Для сравнения также были построены наборы тестовых данных. Они использовали специально разработанную анатомическую трехмерную модель области левого желудочка для моделирования кровотока. Эксперименты показали, что предложенная предварительная фильтрация и межкадровые веса значительно улучшают качество развертки. Работа выполнена в сотрудничестве с академиком В.А. Сандриковым и заведующей лабораторией Т.Ю. Кулагиной.

4.3 Ультразвуковая диагностика фиброза печени

Еще одной интересной задачей медицинского анализа изображений является задача анализа ультразвуковых изображений печени для диагностики фиброза печени. Главной особенностью задачи является нечеткость самой структуры изображения и диффузность фиброза. Эти ограничения не позволяют использовать для анализа все изображение целиком, что сводит задачу к применению текстурного анализа небольших интересующих областей изображения с чистой текстурой (Рис. 14). В

результате мы предложили полуавтоматический метод диагностики фиброза, основанный на текстурном анализе и машинном обучении [55].

Основным недостатком ультразвуковых изображений, обусловленным физикой процесса, является наличие в изображении специфического мультипликативного шума, называемого спекл-шумом. Поэтому проведено отдельное исследование для оценки влияния уровня спекл-шума и использования методов шумоподавления на текстурный анализ [25]. Конечным результатом исследования стал комплексный алгоритм диагностики фиброза печени с использованием ультразвуковых изображений, данных эластографии и предложенных новых методов спекл-шумоподавления и текстурного анализа с помощью методов машинного обучения [26].

Работа выполнена в сотрудничестве с профессором Ю.Р. Камаловым из РНЦХ им. акад. Б.В. Петровского.




Рис. 14 Визуализация выбора областей интереса для анализа текстур и предсказания соответствующего класса для задачи диагностики фиброза печени. H0 соответствует отсутствию болезни, H1 соответствует фиброзу. Истинными значениями являются H0 для (a), (b) и H1 для (c).

4.4 КТ-перфузия головного мозга

Количественный анализ кровотока в ткани головного мозга является одной из важных задач нейрохирургии, которая возникает при диагностировании острого ишемического инсульта. Эту проблему можно решить с помощью перфузионной компьютерной

28

томографии. Существуют различные методы извлечения количественных характеристик мозгового кровотока из данных КТ-перфузии, различающиеся степенью помехоустойчивости. Более помехоустойчивые методы позволяют снизить дозы облучения при проведении обследования больного. Поэтому разработка помехоустойчивых методов является важной задачей. Классические подходы к решению этой задачи основаны на методе сингулярного разложения (SVD) с регуляризацией Тихонова и методах минимизации полной вариации (TV). Эти методы уступили предложенному нами новому алгоритму, использующему минимизацию полной обобщенной вариации [57], но затем мы показали, что более качественный метод оценки количественных характеристик мозгового кровотока может быть получен при проекции решения в процессе минимизации этого функционала на множество монотонных функций [58]. Работа выполнена в сотрудничестве с профессором В.А. Лукшиным и академиком Д.Ю. Усачевым из НМИЦ нейрохирургии им. ак. Н.Н. Бурденко.

4.5 Диагностика болезни Альцгеймера

В последнее десятилетие компьютерная ранняя диагностика болезни Альцгеймера и ее продромальной формы, легких когнитивных нарушений стала предметом обширных исследований. Попытки распознать раннюю стадию заболевания и включить это распознавание в общий скрининг населения привели к задаче определения стадии болезни Альцгеймера путем анализа 3D-изображений головного мозга человека, полученных в модальностях МРТ, ДТ-МРТ, ПЭТ. В нашем исследовании мы предложили несколько подходов на основе СНС с учетом специфики задачи. Решения были основаны на применении переноса обучения [1], построении трехмерных сверточных нейронных сетей [23] и оптимизации архитектур и количества параметров

модели классификации [24]. Работа выполнена в сотрудничестве с лабораторией профессора Jenny Benois-Pineau из Университета Бордо, Франция.

4.6 Дерматология

Были исследованы различные задачи анализа и обработки изображений в дерматологии. К ним относятся проблемы нахождения границ эпидермиса, дермы и подкожной жировой клетчатки при высокочастотном ультразвуковом исследовании [105], удаление волос на дерматологических изображениях с использованием метода деформации пиксельной сетки [85], основанный на поиске хребтовых структур метод диагностики пузырчатки по иммунофлуоресцентным изображениям [16], обнаружение области эпидермиса в иммунофлуоресцентной микроскопии [14] и адаптивное подавление шумов на дерматологических изображениях с использованием проекционного метода Эрмита для алгоритма нелокальных средних [15].

Работа выполнена совместно с профессором Н.В. Махневой из МОНИКИ им. М.Ф. Владимирского.

4.7 Анализ Рентгеновских Снимков Грудной Клетки

Были предложены основанный на глубоком обучении подход к определению уровня жесткости и система автоматического определения отклонения изображений от целевого набора для СНС анализа рентгеновского изображения легких [11, 12, 94]. Алгоритмы оценивают уровень жесткости по количеству отчетливо видимых грудных позвонков. Разработан метод рентгенологической диагностики туберкулеза грудной клетки на базе СНС. Он был использован для исследования влияния прореживания набора данных в соответствии с предсказанным уровнем жесткости изображения на качество диагностики. Исследование выявило повышение точности диагностики после

отбрасывания изображений экстремальных уровней жесткости из обучающего набора данных. Работы выполнены в сотрудничестве с профессором Л.Е. Паролиной из «НМИЦ ФПИ» Минздрава России, г. Москва, и медиками НПЦ «Фтизиатрия» им. Е.Н. Андреева Республики Саха (Якутск, Россия), возглавляемого Е.С. Прокопьевым.

4.8 Анализ Изображений Клеток

Одним из наиболее быстро развивающихся направлений компьютерных наук является анализ микроскопических изображений клеток. За последние несколько лет мы разработали несколько методов и алгоритмов, которые помогают биологам анализировать свои данные.

4.8.1 Анализ изображений живых клеток

В последние годы мы разработали несколько методов анализа изображений, которые были применены к практическим задачам анализа изображений живых клеток. А именно, мы разработали метод отслеживания внутриклеточных структур в последовательностях изображений флуоресцентной микроскопии, который был использован для исследования механизмов, лежащих в основе движения ядерных телец, с помощью экспериментально индуцированных интерфазных пренуклеоларных телец (ИПНТ) [5]. Краеугольным камнем подхода к отслеживанию ИПНТ в этой работе было использование техники совмещения изображений клеток [112] (подробности см. в Разделе 4.8.2), которая позволяла компенсировать глобальное движение ядра и анализировать только локальное движение ИПНТ. Мы развили предложенный подход и опубликовали его в качестве протокола исследования в главе книги [108] вместе с исходным кодом для применения в более широком диапазоне биологических практических задач. Работа выполнена совместно с группой профессора Е.В. Шевалы из НИИ ФХБ имени А.Н. Белозерского МГУ имени М.В. Ломоносова.

4.8.2 Совмещение изображений клеток

В клинической практике часто бывает необходимо одновременно анализировать несколько изображений одного и того же органа. Изображения могут быть получены в разных модальностях, в разные моменты времени или для разных объектов. Проблема актуальна для различных видов данных, таких как МРТ, УЗИ, рентгенография, компьютерная томография, микроскопия и другие. Проблема одновременного анализа изображений заключается в том, что изображения, полученные в разных модальностях, в разные моменты времени или для разных пациентов содержат деформированные различным образом объекты. Это происходит, поскольку изображения не могут быть сняты одновременно, а снимаемые объекты подвергаются деформации или движению в процессе получения изображений. Таким образом, совмещение изображений является ключевой задачей в области анализа медицинских и биологических изображений.

Проблема совмещения актуальна и для изображений криоэлектронной микроскопии (крио-ЭМ). Совмещение отдельных частиц на изображениях крио-ЭМ является одним из важнейших этапов реконструкции 3D-модели. В 2017 году мы разработали корреляционный подход для совмещения проекционных изображений криоэлектронной микроскопии [2], который позволил совмещать изображения более чем в 300 раз быстрее, чем жадный итерационный подход. Сложность задачи связана с экстремальным уровнем шума на изображениях крио-ЭМ.

При микроскопическом анализе изображений живых клеток задача совмещения возникает при анализе движения внутриклеточных структур в живых клетках. Это сложная задача, поскольку живые клетки движутся и деформируются в процессе визуализации. Наблюдаемое движение внутриклеточных структур состоит из двух компонентов: локального движения субструктур и глобального движения ядра,

включающего смещение и деформацию ядра. Для получения информации о чистом движении внутриклеточных субструктур необходимо компенсировать глобальное движение ядра. Обычно это делается с помощью совмещения изображений. В 2018 году был разработан нежесткий метод совмещения изображений клеток в последовательностях изображений флуоресцентной микроскопии [112]. Основная идея метода заключается в использовании обоснованной физической модели нелинейного упругого движения, основанной на уравнении Навье, которая была применена для моделирования нежесткого движения ядра. Эта работа была начата, когда Д.В. Сорокин находился на стажировке в Центре анализа биомедицинских изображений Университета Масарика, Брно, Чешская Республика, в сотрудничестве с доктором Р. Matula. Полученные результаты позволили решить проблему компенсации глобального движения клеток и были использованы в алгоритмах анализа движения живых клеток в биологических исследованиях [5, 108].

Мы также разработали метод нежесткого совмещения и компенсации неравномерной освещенности изображений мозга грызунов, полученных с помощью вживленного минископа [103].

Задача совмещения также является важной частью гистологического анализа изображений [7, 101] (см. Раздел 4.1).

4.8.3 Трекинг и сегментация клеток

Сегментация внутриклеточных структур и мелких частиц является еще одной распространенной задачей в анализе микроскопических изображений живых клеток.

Мы разработали подход для обнаружения структур, индуцированных лазером, на изображениях ядер живых клеток [33]. Подход основан на методе активных контуров, и результаты работы были использованы для разработки стандартного набора данных

для оценки совмещения изображений клеток, который в дальнейшем использовался в [112] и последующих работах по этой теме для оценки методов совмещения изображений клеток.

Автоматический трекинг клеток и субклеточных структур на изображениях флуоресцентной микроскопии является чрезвычайно важной задачей. Первое позволяет анализировать жизненный цикл отдельных клеток через их миграцию, рост и размножение. Последнее позволяет анализировать, например, подвижность флуоресцентно окрашенных актиновых филаментов [34], для которых мы разработали метод автоматического отслеживания. Этот анализ движения филаментов важен для исследования мышечных функций.

Отслеживание клеток недавно сформировало отдельную хорошо известную область анализа биомедицинских изображений. Соревнование Cell Tracking Challenge (CTC), впервые организованное в 2012 году, значительно стимулировало исследования в этой области и привело к развитию многих широко используемых методов сегментации и трекинга. Например, широко распространенная архитектура сегментационной СНС U-Net изначально была разработана для решения этой задачи.

В 2018 году в сотрудничестве с группой профессора Yasushi Okada (Токийский университет) мы разработали подход к трекингу клеток для последовательностей изображений двумерной эпифлуоресцентной микроскопии [31], который позволил превзойти результат трекинга с помощью существующего полуавтоматического метода, ранее использовавшегося для этой задачи. Подход был расширен в [32] путем введения этапа сегментации на основе обучения со слабой разметкой, что еще больше улучшило результаты.

В 2022 году мы разработали подход сегментации на основе обучения со слабой разметкой [4], который расширил исходную разметку разреженной сегментации с использованием подхода разметки для трекинга и совмещения изображений клеток. Предлагаемый подход занял третье место на наборе данных Fluo-C2DL-Huh7 эталонного теста сегментации клеток CTC в апреле 2022 года. Результаты предлагаемого подхода на основе обучения со слабой разметкой по сравнению с обычным обучением с использованием только предоставленной истинной разметки представлены на Рис. 15.

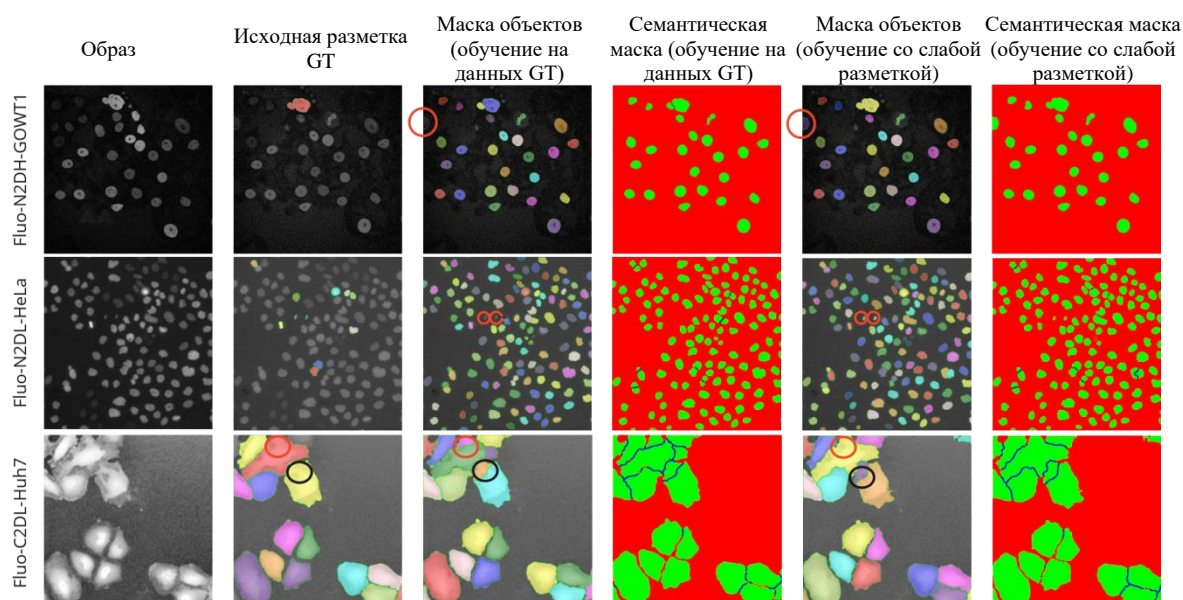


Рис. 15 Результаты сегментации для наборов данных Fluo-N2DH-GOWT1, Fluo-N2DL-HeLa и Fluo-C2DL-Huh7 соревнования CTC. Красные окружности указывают на улучшение результатов при использовании предложенного в [4] подхода обучения с использованием слабой разметки: клетки на границах кадра сегментированы в отличие от базового метода сегментации, обученного на исходных данных GT. Белые окружности показывают улучшение разделения соприкасающихся клеток. Черные окружности показывают ошибки, допущенные обоими подходами для набора данных Fluo-C2DL-Huh7.

4.8.4 Синтез изображений клеток

Для объективной оценки методов анализа биомедицинских изображений требуется множество разнообразных наборов изображений, сопровождаемых эталонной разметкой. Для многих задач создание таких наборов данных действительно занимает много времени, особенно из-за создания эталонной разметки, которая должна выполняться квалифицированными специалистами вручную. Другой способ получения требуемых данных — синтез реалистичных изображений того же класса. Если синтезированные данные реалистичны, это позволяет генерировать как можно больше данных, и эталонная разметка в этом случае генерируется самим методом синтеза изображений. Еще одним ценным качеством таких данных может быть их использование для обучения методов машинного обучения в тех случаях, когда отсутствуют реальные биомедицинские данные со справочной разметкой. Таким образом, разработка методов синтеза изображений становится очень важной задачей.

В сотрудничестве с исследовательскими группами из Чехии, Испании и Франции мы разработали методы синтеза изображений для создания реалистичных изображений клеток с филоподиями с изначально сгенерированными масками сегментации и разметкой для трекинга. Методы представлены в серии работ. Первоначальный подход для подтверждения концепции был представлен в [113], где мы смоделировали рост филоподий и упругое движение отдельной клетки, которые затем были преобразованы в последовательности трехмерных изображений с использованием методов виртуальной микроскопии. В [114] работа была улучшена за счет включения в метод более сложных моделей, в результате чего появилось онлайн-приложение под названием FiloGen, которое позволяет генерировать последовательности изображений различных типов филоподий, контролирующего развитие филоподий, движение и

параметры виртуальной микроскопии. Дальнейшая работа [98] была сосредоточена на взаимодействии множественных клеток с филоподиями. Работа над FiloGen была начата, когда Д.В. Сорокин находился на стажировке в Центре анализа биомедицинских изображений Университета Масарика, Брно, Чешская Республика, в сотрудничестве с доктором M. Maška .

Данные, полученные с помощью FiloGen, были использованы для разработки современных методов сегментации и отслеживания клеток с филоподиями для изображений 3D-флуоресцентной микроскопии в [66] и [8].

Другим примером реалистичного метода синтеза биомедицинских изображений является синтез изображений криоэлектронной микроскопии и криоэлектронной томографии, разработанный в [3].

4.8.5 Мигающая флуоресцентная микроскопия

Мигающая флуоресцентная микроскопия сверхвысокого разрешения позволяет преодолеть дифракционный предел без использования сложного оборудования. В последние годы для решения проблемы реконструкции резкого изображения высокого разрешения были разработаны различные алгоритмы, основанные на разных подходах: SOFI, MUSICAL, SPARCOM, COLORME, DLBI, 3B и др. Для заданной входной последовательности изображений $\{\bar{y}_t\}_{t=1}^N$, самая широкая постановка задачи состоит в том, чтобы найти по крайней мере одно из следующего: его прообраз высокого разрешения $\{\bar{x}_t\}_{t=1}^N$, среднее арифметическое серии изображений высокого разрешения или какую-либо карту мигания (например, дисперсия пикселей или моменты более высоких порядков). Также может быть доступен оператор размытия и понижения разрешения K и дисперсия шума σ . В большинстве случаев входным изображением считается $\bar{y}_t = K\bar{x}_t + \bar{b} + \bar{n}_\sigma$, где \bar{b} — постоянный фон, а \bar{n}_σ — гауссовский шум.

В [95] представлен вероятностный подход с регуляризацией для реконструкции изображения высокого разрешения и проведен анализ качества его работы в различных условиях. Задача определяется следующим образом:

$$\{\bar{x}_t^*\}_{t=1}^N, \bar{\mu}^*, \Lambda^*, \bar{\sigma}^* = \arg \min_{\substack{\{\bar{x}_t\}_{t=1}^N \geq 0, \\ \bar{\mu} \geq 0, \Lambda > 0, \bar{\sigma} \geq 0}} \sum_{t=1}^N \left[\begin{aligned} & (\bar{y}_t - K\bar{x}_t)^T (\text{diag}(\bar{\sigma}))^{-1} (\bar{y}_t - K\bar{x}_t) + \\ & + (\bar{x}_t - \bar{\mu})^T \Lambda (\bar{x}_t - \bar{\mu}) - \\ & - \ln |\Lambda| + \ln |\text{diag}(\bar{\sigma})| \end{aligned} \right] + \\ + \alpha \|\bar{\mu}\|^2 - \beta \ln |\Lambda| + \text{Tr}(\Gamma \Lambda),$$

где $\bar{\mu}$, Λ , $\bar{\sigma}$ — среднее серии изображений, матрица, обратная ковариационной матрице мигающей последовательности, и попиксельные дисперсии гауссовского шума изображения соответственно, α , β — параметры регуляризации, а Γ — матрица регуляризации.

Будучи представлением карты мигания изображения и благодаря отсутствию на ней немигающего фона, наиболее информативной является основная диагональ ковариационной матрицы последовательности изображений мигающей флуоресцентной микроскопии. Чтобы найти ее, недавно было предложено семейство вычислительно эффективных алгоритмов, и важность стабилизатора становится для них заметной. Влияние различных стабилизаторов $\Omega(x)$, в том числе подхода RED (регуляризация через подавление шума), основанного на методах NLM (метод нелокальных средних) и TV (метод полной вариации), на решения задачи, определяемой как

$$\min_{r_{\bar{x}} \geq 0} \frac{1}{2} \left\| R_{\bar{y}} - K \text{diag}(r_{\bar{x}}) K^T - \sigma I \right\|_F^2 + \lambda \Omega(r_{\bar{x}}),$$

где $R_{\bar{y}}$, $r_{\bar{x}}$, σ — ковариационная матрица входной последовательности изображений, попиксельные дисперсии его прообраза и дисперсия гауссовского шума соответственно, рассмотрено в [93].

Работа по мигающей флуоресцентной микроскопии сверхвысокого разрешения была выполнена в сотрудничестве с лабораторией профессора Yasushi Okada из Токийского университета.

5 ЗАКЛЮЧЕНИЕ

Быстрое развитие методов искусственного интеллекта в анализе изображений и приложениях позволяет решать общие и прикладные задачи во многих случаях гораздо эффективнее, чем классические математические методы. Это также включает в себя огромный прогресс в анализе биомедицинских изображений. Тем не менее, возникает много проблем. Методы становятся гораздо более зависимыми от используемого набора данных, алгоритмы могут становиться менее устойчивыми и т. д. Наша практика показывает, что оптимальные решения обычно могут быть найдены гибридными методами, когда мы совместно используем методы искусственного интеллекта и классические математические методы обработки анализа и повышения качества изображений.

6 БЛАГОДАРНОСТИ

В состав научной школы входят сотрудники Лаборатории математических методов обработки изображений; ее покойный соучредитель Д.В. Юрин; бывшие члены А.М. Ятченко, М.М. Мизотин и А.С. Лукин; нынешние аспиранты М.А. Пенкин, Д.А. Люков, В.Е. Карнаухов, Н.А. Аношина, Т.Б. Сагиндыков; аспиранты, защитившие кандидатские диссертации М. Наджафи, А.А. Горохов, Д.Н. Корчагин, В.Н. Цибанов, А.А. Насонова (Черноморец), А.В. Умнов, А.А. Довганич и более 150 нынешних и бывших студентов. Мы благодарны им и всем нашим коллегам за многолетнюю совместную работу.

Мы искренне благодарим профессора А.М. Денисова, профессора А.В. Разгулина, профессора Ю.В. Шеваля, профессора П.Г. Малькова и И.А. Михайлова (МГУ им. М.В. Ломоносова); профессора S. Stanković и профессора I. Ogrović (Университет Черногории); академика В.А. Сандрикова, заведующую лабораторией Т.Ю. Кулагину и профессора Ю.Р. Камалова (РНЦХ им. академика Б.В. Петровского); профессора В.А. Лукшина и академика Д.Ю. Усачева (НМИЦ нейрохирургии им. академика Н.Н. Бурденко); профессора Jenny Benois-Pineau (Университет Бордо); профессора Н.В. Махневу (МОНИКИ им. М.Ф. Владимирского); профессора Л.Е. Паролину («НМИЦ ФПИ» Минздрава России); Е.Г. Прокопьева (НПЦ «Фтизиатрия» им. Е.Н. Андреева); доктора P. Matula и доктора M. Maška (Масариков университет); профессора Y.Okada (Токийский университет) и других научных коллег за плодотворное сотрудничество.

Мы также очень благодарны нашим нынешним и бывшим партнерам по давним совместным международным проектам за возможность участия в их деятельности: профессору K.-L. Chung (Национальный Тайваньский университет науки и технологий) [9], профессору Y. Ding (Чжэцзянский университет) [10, 20, 118] и профессору M.C.Q. Farias (Университет Бразилиа) [120].

7 ФИНАНСИРОВАНИЕ

Полученные результаты, созданные идеи и методы используются и развиваются в проекте по анализу гистологических изображений, поддерживаемом грантом РФФ 22-41-02002.

8 ЛИТЕРАТУРА

- [1] K. Aderghal, A. Khvostikov, A. Krylov, J. Benois-Pineau, K. Afdel, and G. Catheline, “Classification of Alzheimer disease on imaging modalities with deep CNNs using cross-modal transfer learning,” in Proceedings of the 2018 IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS), Karlstad, Sweden, 345–350 (2018). <https://doi.org/10.1109/CBMS.2018.00067>
- [2] N. A. Anoshina, A. S. Krylov, and D. V. Sorokin, “Correlation-based 2D registration method for single particle cryo-EM images,” in 2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA), 1–6 (2017). <https://doi.org/10.1109/IPTA.2017.8310125>
- [3] N. A. Anoshina, T. B. Sagindykov, and D. V. Sorokin, “A method for generation of synthetic 2D and 3D Cryo-EM images,” *Programming and Computer Software*, 44(4), 240–247 (2018). <https://doi.org/10.1134/S0361768818040023>
- [4] N. A. Anoshina and D. V. Sorokin, “Weak supervision using cell tracking annotation and image registration improves cell segmentation,” in 2022 Eleventh International Conference on Image Processing Theory, Tools and Applications (IPTA), 1–5 (IEEE, 2022). <https://doi.org/10.1109/ipta54936.2022.9784140>
- [5] E. A. Arifulin, D. V. Sorokin, A. V. Tvorogova, M. A. Kurnaeva, Y. R. Musinova, O. A. Zhironkina, S. A. Golyshchev, S. S. Abramchuk, Y. S. Vassetzky, and E. V. Sheval, “Heterochromatin restricts the mobility of nuclear bodies,” *Chromosoma*, 127(4), 529–537 (2018). <https://doi.org/10.1007/s00412-018-0683-8>
- [6] L. A. Blagonravov, S. N. Skovorod’ko, A. S. Krylov, L. A. Orlov, V. A. Alekseev, and E. E. Shpilrain, “Phase transition in liquid cesium near 590K,” *Journal of Non-*

Crystalline Solids, 277(2), 182–187 (2000). [https://doi.org/10.1016/S0022-3093\(00\)00315-X](https://doi.org/10.1016/S0022-3093(00)00315-X)

- [7] J. Borovec, J. Kybic, I. Arganda-Carreras, D. V. Sorokin, G. Bueno, A. V. Khvostikov, S. Bakas, E. I. Chang, S. Heldmann, K. Kartasalo, L. Latonen, J. Lotz, M. Noga, S. Pati, K. Punithakumar, P. Ruusuvuori, A. Skalski, N. Tahmasebi, M. Valkonen, L. Venet, Y. Wang, N. Weiss, M. Wodzinski, Y. Xiang, Y. Xu, Y. Yan, P. Yushkevich, S. Zhao, and A. Muñoz-Barrutia, “ANHIR: Automatic non-rigid histological image registration challenge,” *IEEE Transactions on Medical Imaging*, 39(10), 3042–3052 (2020). <https://doi.org/10.1109/TMI.2020.2986331>
- [8] C. Castilla, M. Maška, D. V. Sorokin, E. Meijering, and C. Ortiz-de Solórzano, “3-D quantification of filopodia in motile cancer cells,” *IEEE Transactions on Medical Imaging*, 38(3), 862–872 (2019). <https://doi.org/10.1109/TMI.2018.2873842>
- [9] K.-L. Chung, Y.-H. Huang, S.-M. Shen, A. S. Krylov, D. V. Yurin, and E. V. Semeikina, “Efficient sampling strategy and refinement strategy for randomized circle detection,” *Pattern Recognition*, 45(1), 252–263 (2012). <https://doi.org/10.1016/j.patcog.2011.07.004>
- [10] Y. Ding, R. Deng, X. Xie, X. Xu, Y. Zhao, X. Chen, and A. S. Krylov, “No-reference stereoscopic image quality assessment using convolutional neural network for adaptive feature extraction,” *IEEE ACCESS*, 6, 37595–37603 (2018). <https://doi.org/10.1109/ACCESS.2018.2851255>
- [11] A. A. Dovganich, A. V. Khvostikov, A. S. Krylov, and L. E. Parolina, “Automatic quality control in lung X-ray imaging with deep learning,” *Computational Mathematics and Modeling*, 32(3), 276–285 (2021). <https://doi.org/10.1007/s10598-021-09539-6>
- [12] A. A. Dovganich, A. V. Khvostikov, Y. A. Pchelintsev, A. S. Krylov, Y. Ding, and C. Q. Farias Mylene, “Automatic out-of-distribution detection methods for improving

- the deep learning classification of pulmonary X-ray images,” *Journal of Image and Graphics*, 10(2), 56–63 (2022). <https://doi.org/10.18178/joig.10.2.56-63>
- [13] A. A. Dovganich and A. S. Krylov, “A nonlocal image denoising algorithm using the structural similarity metric,” *Programming and Computer Software*, 45(4), 141–146 (2019). <https://doi.org/10.1134/S0361768819040029>
- [14] A. Dovganich, A. Krylov, A. Nasonov, and N. Makhneva, “Epidermis area detection for immunofluorescence microscopy,” in *9th International Conference on Graphics and Image Processing (ICGIP 2017)*, 1061522 (2017). <https://doi.org/10.1117/12.2302591>
- [15] A. Dovganich, N. Mamaev, A. Krylov, and N. Makhneva, “Dermatological image denoising using adaptive henlm method,” *ISPRS Journal of Photogrammetry and Remote Sensing*, 42(2/W12), 47–52 (2019). <https://doi.org/10.5194/isprs-archives-xlii-2-w12-47-2019>
- [16] A. Dovganich, Y. Pchelintsev, A. Nasonov, and A. Krylov, “Ridge-based method for pemphigus diagnosis on immunofluorescence images,” in *Proceedings of the 26th International Conference on Computer Graphics and Vision GraphiCon’2016*, Nizhny Novgorod, Russia, 170–174 (2016).
- [17] F. Guryanov and A. Krylov, “Fast medical image registration using bidirectional empirical mode decomposition,” *Signal Processing: Image Communication*, 59, 12–17 (2017). <https://doi.org/10.1016/j.image.2017.04.003>
- [18] F. A. Guryanov and A. S. Krylov, “Optimization method for cell image registration,” *Programming and Computer Software*, 44(4), 266–270 (2018). <https://doi.org/10.1134/s0361768818040072>
- [19] A. D. Gusev, A. V. Nasonov, and A. S. Krylov, “Fast parallel grid warping-based image sharpening method,” *Programming and Computer Software*, 43(4), 230–233 (2017). <https://doi.org/10.1134/S036176881704003X>

- [20] L. Jiale, Y. Sun, S. Luo, Z. Zhu, H. Dai, A. S. Krylov, Y. Ding, and L. Shao, "P2V-RCNN: Point to voxel feature learning for 3D object detection from point clouds," *IEEE ACCESS*, 9, 98249–98260 (2021). <https://doi.org/10.1109/ACCESS.2021.3094562>
- [21] V. E. Karnaukhov, A. S. Krylov, Y. Ding, and C. Q. Farias Mylene, "Hybrid method for biomedical image poisson denoising," in *Proceedings of the 2020 5th International Conference on Biomedical Signal and Image Processing*, 32–36 (2020),. <https://doi.org/10.1145/3417519.3417553>
- [22] N. A. Khanina, E. V. Semeikina, and D. V. Yurin, "Scale-space color blob and ridge detection," *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 22(1), 221–227 (2012). <https://doi.org/10.1134/S1054661812010221>
- [23] A. Khvostikov, K. Aderghal, J. Benois-Pineau, A. Krylov, and G. Catheline, "3D CNN-based classification using sMRI and MD-DTI images for Alzheimer disease studies," *ArXiv e-prints*, 1–14 (2018). <https://doi.org/10.48550/arXiv.1801.05968>
- [24] A. Khvostikov, K. Aderghal, A. Krylov, G. Catheline, and J. Benois-Pineau, "3D inception-based CNN with sMRI and MD-DTI data fusion for Alzheimer's disease diagnostics," *ArXiv e-prints*, 1–13 (2018). <https://doi.org/10.48550/arXiv.1809.03972>
- [25] A. Khvostikov, A. Krylov, J. Kamalov, and A. Megroyan, "Influence of ultrasound despeckling on the liver fibrosis classification," in *Proceedings of the 5th IEEE International Conference on Image Processing, Theory, Tools and Applications, Orleans, France*, 440–445 (2015). <https://doi.org/10.1109/IPTA.2015.7367183>
- [26] A. Khvostikov, A. Krylov, J. Kamalov, and A. Megroyan, "Ultrasound despeckling by anisotropic diffusion and total variation methods for liver fibrosis diagnostics," *Signal Processing: Image Communication*, 59, 3–11 (2017). <https://doi.org/10.1016/j.image.2017.09.005>

- [27] A. Khvostikov, A. Krylov, I. Mikhailov, O. Kharlova, N. Oleynikova, and P. Malkov, “Automatic mucous glands segmentation in histological images,” *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, XLII-2/W12, 103–109 (2019). <https://doi.org/10.5194/isprs-archivesXLII-2-W12-103-2019>
- [28] A. Khvostikov, A. Krylov, I. Mikhailov, and P. Malkov, “Trainable active contour model for histological image segmentation,” *Scientific Visualization*, 11(3), 64–75 (2019). <https://doi.org/10.26583/sv.11.3.06>
- [29] A. Khvostikov, A. S. Krylov, I. Mikhailov, and P. Malkov, “CNN assisted hybrid algorithm for medical images segmentation,” in *Proceedings of the 2020 5th International Conference on Biomedical Signal and Image Processing*, 14–19 (2020). <https://doi.org/10.1145/3417519.3417557>
- [30] A. Khvostikov, A. Krylov, I. Mikhailov, P. Malkov, and N. Danilova, “Tissue type recognition in whole slide histological images,” *CEUR Workshop Proceedings*, 3027, 50 (2021). <https://doi.org/10.20948/graphicon-2021-3027-496-507>
- [31] A. Y. Kondratiev, Y. Hideyuki, O. Yasushi, and D. V. Sorokin, “A method for automatic tracking of cell nuclei in 2D epifluorescence microscopy image sequences,” in *The eighth International Conference on Image Processing Theory, Tools and Applications (IPTA) 2018*, 1–6 (2018). <https://doi.org/10.1109/IPTA.2018.8608156>
- [32] A. Y. Kondratiev, H. Yaginuma, Y. Okada, A. S. Krylov, and D. V. Sorokin, “A method for automatic tracking of cell nuclei with weakly-supervised mitosis detection in 2D microscopy image sequences,” in *Proceedings of the 2020 5th International Conference on Biomedical Signal and Image Processing*, 67–73 (2020). <https://doi.org/10.1145/3417519.3417558>

- [33] A. Y. Kondrat'ev and D. V. Sorokin, "Automatic detection of laser-induced structures in live cell fluorescent microscopy images using snakes with geometric constraints," in IEEE 23rd International Conference on Pattern Recognition, ICPR 2016, 326–331 (2016). <https://doi.org/10.1109/ICPR.2016.7899655>
- [34] D. A. Kononykhin, V. Y. Berg, D. A. Ovsyannikov, A. S. Krylov, and D. V. Sorokin, "A method for actin filament tracking in fluorescent microscopy images," CEUR Workshop Proceedings, 2744, 1–10 (2020). <https://doi.org/10.51130/graphicon-2020-2-3-37>
- [35] D. Kortchagine and A. Krylov, "Image database retrieval by fast Hermite projection method," in Proceedings of the 15th International Conference on Computer Graphics and Vision GraphiCon'2005, Novosibirsk, Akademgorodok, Russia, 137–140 (2005).
- [36] A. Krylov, F. Guryanov, N. Mamaev, and D. Yurin, "Fast estimation of downsampling factor for biomedical image registration," in Proceedings of 2018 3rd International Conference on Biomedical Imaging, Signal Processing (ICBSP 2018), Bari, Italy, 36–40 (2018). <https://doi.org/10.1145/3288200.3288203>
- [37] A. Krylov, V. Karnaukhov, N. Mamaev, and A. Khvostikov, "Hybrid method for biomedical image denoising," in Proceedings of the 2019 4th International Conference on Biomedical Imaging, Signal Processing, 60–64 (ACM, 2019). <https://doi.org/10.1145/3366174.3366184>
- [38] A. Krylov and D. Korchagin, "Fast Hermite projection method," Lecture Notes in Computer Science, 4141, 329–338 (2006). https://doi.org/10.1007/11867586_31
- [39] A. Krylov and D. Kortchagine, "Projection filtering in image processing," in Proceedings of the 10th International Conference on Computer Graphics and Vision GraphiCon'2000, Moscow, Russia, 42–45 (2000).

- [40] A. S. Krylov, A. V. Kutovoi, and K. L. Wee, “Texture parameterization with Hermite functions,” in Proceedings of the 12th International Conference on Computer Graphics and Vision GraphiCon’2002, 190–194 (2002).
- [41] A. S. Krylov and A. V. Liakishev, “Numerical projection method for inverse Fourier type transforms and its application,” Numerical Functional Analysis and Optimization, 21(1-2), 205–216 (2000). <https://doi.org/DOI:10.1080/01630560008816949>
- [42] A. Krylov and A. Nasonov, “Adaptive total variation deringing method for image interpolation,” in Proceedings of International Conference on Image Processing ICIP’08, San Diego, USA, 2608–2611 (2008). <https://doi.org/10.1109/ICIP.2008.4712328>
- [43] A. S. Krylov and A. V. Nasonov, “Adaptive image deblurring with ringing control,” in Proceedings of the 5th International Conference on Image and Graphics, ICIG 2009, Xi’an, Shanxi, China, 72–75 (2009). <https://doi.org/10.1109/ICIG.2009.136>
- [44] A. S. Krylov and A. V. Nasonov, “3D image sharpening by grid warping,” Lecture Notes in Computer Science (IScIDE2015), 9242, 441–450 (2015). https://doi.org/10.1007/978-3-319-239897_45
- [45] A. S. Krylov, A. V. Nasonov, and A. A. Chernomorets, “Combined linear resampling method with ringing control,” in Proceedings of the 19th International Conference on Computer Graphics and Vision GraphiCon’2009, Moscow, Russia, 163–165 (2009).
- [46] A. Krylov, A. Nasonov, K. Chesnakov, A. Nasonova, J. S. Oh, K. Uk, and S. M. Park, “Vessel preserving CNN-based image resampling of retinal images,” Lecture Notes in Computer Science, 10882, 589–597 (2018). https://doi.org/10.1007/978-3-319-93000-8_67
- [47] A. Krylov, A. Nasonov, and Y. Pchelintsev, “Single parameter post-processing method for image deblurring,” in Proceedings of the 7th International Conference on Image

Processing Theory, Tools and Applications (IPTA), 1–7 (2017).
<https://doi.org/10.1109/IPTA.2017.8310093>

- [48] A. S. Krylov, A. V. Nasonov, A. V. Razgulin, and T. E. Romanenko, “A post-processing method for 3D fundus image enhancement,” in Proceedings of the International Conference on Signal Processing (ICSP2016), 49–52 (2016).
<https://doi.org/10.1109/ICSP.2016.7877794>
- [49] A. Krylov, A. Nasonov, and D. Sorokin, “Face image super-resolution from video data with nonuniform illumination,” in 18th International Conference on Computer Graphics GraphiCon’2008, 150–155 (2008).
- [50] A. Krylov, A. Nasonov, and O. Ushmaev, “Image super-resolution using fast deconvolution,” in Proceedings of 9th Conference on Pattern Recognition and Image Analysis: New Information Technologies, 1(2), 362–364 (2008).
- [51] A. S. Krylov, A. A. Nasonova, and A. V. Nasonov, “Image enhancement by noniterative grid warping,” *Pattern Recognition and Image Analysis*, 26(1), 161–164 (2016). <https://doi.org/10.1134/S1054661816010132>
- [52] A. Krylov, M. Penkin, N. Mamaev, and A. Khvostikov, “How to choose adaptively parameters of image denoising methods?” in 2019 Ninth International Conference on Image Processing Theory, Tools and Applications (IPTA), 1–6 (2019).
<https://doi.org/10.1109/IPTA.2019.8936109>
- [53] A. S. Krylov, J. F. Poliakoff, and M. Stockenhuber, “An Hermite expansion method for EXAFS data treatment and its application to Fe K-edge spectra,” *Physical Chemistry Chemical Physics*, 2(24), 5743–5749 (2000). <https://doi.org/10.1039/B004346J>
- [54] A. Krylov, D. Sorokin, D. Yurin, and E. Semeikina, “Use of color information for keypoints detection and descriptors construction,” *Lecture Notes in Computer Science*, 7202, 389–396 (2012). https://doi.org/10.1007/978-3-642-31919-8_50

- [55] A. V. Kvostikov, A. S. Krylov, and U. R. Kamalov, “Ultrasound image texture analysis for liver fibrosis stage diagnostics,” *Programming and Computer Software*, 41(5), 273–278 (2015). <https://doi.org/10.1134/S0361768815050059>
- [56] A. Lukin, A. Krylov, and A. Nasonov, “Image interpolation by super-resolution,” in *Proceedings of the 16th International Conference GraphiCon’2006*, 239–242 (2006).
- [57] D. A. Lyukov, A. S. Krylov, and V. A. Lukshin, “Total generalized variation method for deconvolution-based CT brain perfusion,” *CEUR Workshop Proceedings*, 2485, 136–139 (2019). <https://doi.org/10.30987/graphicon-2019-2-136-139>
- [58] D. A. Lyukov, A. S. Krylov, V. A. Lukshin, and D. Y. Usachev, “Projection method for deconvolution-based CT brain perfusion,” *Programming and Computer Software*, 46(3), 213–218 (2020). <https://doi.org/10.1134/S0361768820030056>
- [59] N. V. Mamaev and A. S. Krylov, “Using anisotropic diffusion in the multiscale ridge detection method,” *Computational Mathematics and Modeling*, 30(3), 191–197 (2019). <https://doi.org/10.1007/s10598-019-09446-x>
- [60] N. Mamaev, A. Krylov, and D. Yurin, “Choice of the regularization parameter for total variation image denoising using no-reference metric,” in *Proceedings of the International Conferences Interfaces and Human Computer Interaction 2018; Game and Entertainment Technologies 2018; and Computer Graphics, Visualization, Computer Vision and Image Processing 2018*, 253–260 (2018).
- [61] N. V. Mamaev, A. S. Lukin, and D. V. Yurin, “HeNLM–LA: a locally adaptive nonlocal means algorithm based on Hermite functions expansion,” *Programming and Computer Software*, 40(4), 199–207 (2014). <https://doi.org/10.1134/S0361768814040070>
- [62] N. V. Mamaev, A. S. Lukin, and D. V. Yurin, “HeNLM-LA3D: A three-dimensional locally adaptive Hermite functions expansion based non-local means algorithm for CT

applications,” *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 25(4), 706–716 (2015).
<https://doi.org/10.1134/S105466181504015X>

[63] N. Mamaev, D. Yurin, and A. Krylov, “Image ridge denoising using no-reference metric,” *Lecture Notes in Computer Science*, 10617, 591–601 (2017).
https://doi.org/10.1007/978-3-319-703534_50

[64] N. Mamaev, D. Yurin, and A. Krylov, “Choice of the parameter for BM3D denoising algorithm using no-reference metric,” in *2018 7th European Workshop on Visual Information Processing (EUVIP)*, 1–6 (2018).
<https://doi.org/10.1109/EUVIP.2018.8611679>

[65] N. V. Mamaev, D. V. Yurin, and A. S. Krylov, “Finding the parameters of a nonlinear diffusion denoising method by ridge analysis,” *Computational Mathematics and Modeling*, 29(3), 334–343 (2018). <https://doi.org/10.1007/s10598-018-9413-6>

[66] M. Maška, T. Necasova, D. Wiesner, D. V. Sorokin, I. Peterlík, V. Ulman, and D. Svoboda, “Toward robust fully 3D filopodium segmentation and tracking in time-lapse fluorescence microscopy,” in *2019 IEEE International Conference on Image Processing (ICIP)*, 819–823 (IEEE, 2019). <https://doi.org/10.1109/ICIP.2019.8803721>

[67] M. Najafi, A. Krylov, and D. Kortchagine, “Image deblocking with 2-D Hermite transform,” in *Proceedings of the 13th International Conference on Computer Graphics and Vision GraphiCon’2003*, Moscow, Russia, 180–183 (2003).

[68] A. Nasonov, K. Chesnakov, and A. Krylov, “Convolutional neural networks based image resampling with noisy training set,” in *International Conference on Signal Processing (ICSP2016)*, 62–66 (2016). <https://doi.org/10.1109/ICSP.2016.7877797>

[69] A. Nasonov, K. Chesnakov, and A. Krylov, “CNN based retinal image upscaling using zero component analysis,” *International Archives of the Photogrammetry, Remote*

Sensing and Spatial Information Sciences - ISPRS Archives, 24(2W4), 27–31 (2017).

<https://doi.org/10.5194/isprsarchives-XLII-2-W4-27-2017>

- [70] A. V. Nasonov and A. S. Krylov, “Adaptive image deringing,” in Proceedings of the 19th International Conference on Computer Graphics and Vision GraphiCon’2009, Moscow, Russia, 151–154 (2009).
- [71] A. V. Nasonov and A. S. Krylov, “Scale-space method of image ringing estimation,” in Proceedings of International Conference on Image Processing ICIP’09, 2794–2797 (2009). <https://doi.org/10.1109/ICIP.2009.5414172>
- [72] A. V. Nasonov and A. S. Krylov, “Basic edges metrics for image deblurring,” in Proceedings of the 10th Conference on Pattern Recognition and Image Analysis: New Information Technologies, 1, 243–246 (2010).
- [73] A. V. Nasonov and A. S. Krylov, “Fast super-resolution using weighted median filtering,” in Proceedings of the International Conference on Pattern Recognition (ICPR’2010), 2230–2233 (2010). <https://doi.org/10.1109/ICPR.2010.546>
- [74] A. Nasonov and A. Krylov, “An improvement of BM3D image denoising and deblurring algorithm by Generalized Total Variation,” in 2018 7th European Workshop on Visual Information Processing (EUVIP), 1–4 (2018). <https://doi.org/10.1109/EUVIP.2018.8611693>
- [75] A. Nasonov and A. Krylov, “Image sharpening by grid warping with curvature analysis,” in Proceedings of the 15th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS), 262–267 (2019). <https://doi.org/10.1109/SITIS.2019.00051>
- [76] A. V. Nasonov, A. S. Krylov, and K. E. Chesnakov, “An image resampling method using combined directional kernels,” in Proceedings of the 6th European Workshop on

Visual Information Processing EUVIP2016, 1–5 (2016).

<https://doi.org/10.1109/EUVIP.2016.7764602>

- [77] A. Nasonov, A. Krylov, and A. Lukin, “Post-processing by total variation quasi-resolution method for image interpolation,” in Proceedings of the 17th International Conference on Computer Graphics GraphiCon’2007, 178–181 (2007).
- [78] A. Nasonov, A. Krylov, and D. Lyukov, “Image sharpening with blur map estimation using convolutional neural network,” ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 42(2/W12), 161–166 (2019). <https://doi.org/10.5194/isprsarchives-XLII-2-W12-161-201>
- [79] A. Nasonov, A. Krylov, X. Petrova, and M. Rychagov, “Edge-directional interpolation algorithm using structure tensor,” in Proceedings of the 28th annual International Symposium on Electronic Imaging (2016). <https://doi.org/10.2352/ISSN.2470-1173.2016.15.IPAS-026>
- [80] A. V. Nasonov, N. V. Mamaev, O. S. Volodina, and A. S. Krylov, “Automatic choice of denoising parameter in Perona-Malik model,” CEUR Workshop Proceedings, 2485, 144–147 (2019). <https://doi.org/10.30987/graphicon-2019-2-144-147>
- [81] A. V. Nasonov, A. A. Nasonova, and A. S. Krylov, “Edge width estimation for defocus map from a single image,” Lecture Notes in Computer Science, 9386, 15–22 (2015). https://doi.org/10.1007/978-3-319-25903-1_2
- [82] A. Nasonov, Y. Pchelintsev, and A. Krylov, “Grid warping postprocessing for linear motion blur in images,” in Proceedings of the 7th European Workshop on Visual Information Processing (EUVIP), 1–5 (2018). <https://doi.org/10.1109/EUVIP.2018.8611700>
- [83] A. V. Nasonov, O. S. Volodina, and A. S. Krylov, “Non-linear multi-frame image denoising using weighted nuclear norm minimization,” The International Archives of

the Photogrammetry, Remote Sensing and Spatial Information Sciences, 167–170 (2021). <https://doi.org/10.5194/isprsarchives-XLIV-2-W1-2021-167-2021>

- [84] A. Nasonova and A. Krylov, “Deblurred images post-processing by Poisson warping,” *IEEE Signal Processing Letters*, 22(4), 417–420 (2014). <https://doi.org/10.1109/LSP.2014.2361492>
- [85] A. Nasonova, A. Nasonov, A. Krylov, I. Pechenko, A. Umnov, and N. Makhneva, “Image warping in dermatological image hair removal,” *Lecture Notes in Computer Science*, 8815, 159–166 (2014). https://doi.org/10.1007/978-3-319-11755-3_18
- [86] N. Oleynikova, A. Khvostikov, A. Krylov, I. Mikhailov, O. Kharlova, N. Danilova, P. Malkov, N. Ageykina, and E. Fedorov, “Automatic glands segmentation in histological images obtained by endoscopic biopsy from various parts of the colon,” *Endoscopy*, 51(04), OP9 (2019). <https://doi.org/10.1055/s-0039-1681188>
- [87] E. Pavelyeva, “Hermite projection phase-only correlation method in iris key points,” in *The 22nd International Conference on Computer Graphics and Vision GraphiCon’2012*, 128–132 (2012).
- [88] E. Pavelyeva, “The search for matches between the iris key points using Hermite projection phase-only correlation method,” *Systems and Means of Informatics*, 23(2), 74–88 (2013). <https://doi.org/10.14357/08696527130206>
- [89] E. Pavelyeva, “Image processing and analysis based on the use of phase information,” *Computer Optics*, 42(6), 1022–1034 (2018). <https://doi.org/10.18287/2412-6179-2018-42-6-1022-1034>
- [90] E. A. Pavelyeva and A. S. Krylov, “An adaptive algorithm of iris image key points detection,” in *GraphiCon’2010*, 320–323 (2010).

- [91] E. Pavelyeva and A. Krylov, “Image reconstruction from phase using Hermite projection method,” in 11th International Conference “Pattern Recognition and Image Analysis: New Information Technologies” (PRIA-11-2013), 296–299 (2013).
- [92] E. Pavelyeva and A. Krylov, “Synthesis of phase and magnitude of images by Hermite projection method,” *Pattern Recognition and Image Analysis*, 25(2), 187–192 (2015). <https://doi.org/10.1134/S1054661815020200>
- [93] I. A. Pchelintsev, A. V. Nasonov, and A. S. Krylov, “Regularization methods in the analysis of a series of scintillation fluorescence microscopy images,” *Computational Mathematics and Modeling*, 32(2), 111–119 (2021). <https://doi.org/10.1007/s10598-021-09520-3>
- [94] I. A. Pchelintsev, A. V. Khvostikov, A. S. Krylov, L. E. Parolina, N. A. Nikiforova, L. P. Shepeleva, E. S. Prokopev, M. Farias, and Y. Ding, “Analysis of the chest X-ray radiation level for neural network diagnostics of tuberculosis,” in *Prikladnaya Matematika i informatika*, 70, 52–70 (MAKS Press, Moskva, 2022). (In Russian, English version is in print in *Computational Mathematics and Modeling*, 33(2))
- [95] Y. Pchelintsev, A. Nasonov, A. Krylov, S. Enoki, and Y. Okada, “Enhancement algorithms for blinking fluorescence imaging,” in *Proceedings of the 2019 4th International Conference on Biomedical Imaging, Signal Processing*, 72–77 (ACM, 2019). <https://doi.org/10.1145/3366174.3366183>
- [96] M. Penkin, A. Krylov, and A. Khvostikov, “Attention-based convolutional neural network for MRI Gibbs-ringing artifact suppression,” *CEUR Workshop Proceedings*, 2744, 1–12 (2020). <https://doi.org/10.51130/graphicon-2020-2-3-34>
- [97] M. A. Penkin, A. S. Krylov, and A. V. Khvostikov, “Hybrid method for Gibbs-ringing artifact suppression in magnetic resonance images,” *Programming and Computer Software*, 47(3), 207–214 (2021). <https://doi.org/10.1134/s0361768821030087>

- [98] I. Peterlík, D. Svoboda, V. Ulman, D. Sorokin, and M. Maška, “Model-based generation of synthetic 3D time-lapse sequences of multiple mutually interacting motile cells with filopodia,” in Third International Workshop on Simulation and Synthesis in Medical Imaging, SASHIMI 2018, Lecture Notes in Computer Science, 11037, 71–79 (2018). https://doi.org/10.1007/978-3-030-005368_8
- [99] M. Protsenko and E. Pavelyeva, “Iris image key points descriptors based on phase congruency,” *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 167–171 (2019). <https://doi.org/10.5194/isprs-archives-XLII-2-W12-167-2019>
- [100] M. Protsenko and E. Pavelyeva, “Image key point matching by phase congruency,” *Computational Mathematics and Modeling*, 32(3), 297–304 (2021). <https://doi.org/10.1007/s10598-021-09532-z>
- [101] V. A. Pyatov and D. V. Sorokin, “Affine registration of histological images using transformer-based feature matching,” *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 32(3), 626–630 (2022). <https://doi.org/10.1134/S1054661822030324>
- [102] E. Safronova and E. Pavelyeva, “Unsupervised palm vein image segmentation,” in *CEUR Workshop Proceedings*, 2744, 1–12 (2020). <https://doi.org/10.51130/graphicon-2020-2-3-40>
- [103] T. B. Sagindykov, A. R. Brazhe, and D. V. Sorokin, “Preprocessing and registration of miniscope-based calcium imaging of the rodent brain,” *ISPRS Journal of Photogrammetry and Remote Sensing*, 42(2/W12), 185–188 (2019). <https://doi.org/10.5194/isprs-archives-XLII-2-W12-1852019>
- [104] T. B. Sagindykov and E. A. Pavelyeva, “Human image matting based on convolutional neural network and principal curvatures,” *The International Archives of*

Photogrammetry, Remote Sensing and Spatial Information Sciences, 44, 183–187 (2021). <https://doi.org/10.5194/isprsarchives-XLIV-2-W1-2021-183-2021>

- [105] A. Semashko, A. Yatchenko, A. Krylov, A. Bezugly, N. Makhneva, and N. Potekaev, “Border extraction of epidermises, derma and subcutaneous fat in high-frequency ultrasonography,” in Proceedings of the 22nd International Conference on Computer Graphics and Vision GraphiCon’2012, Moscow, Russia, 73–75 (2012).
- [106] I. Sitdikov, F. Guryanov, and A. S. Krylov, “Accelerated mutual entropy maximization for biomedical image registration,” in Proceedings of the 5th IEEE International Conference on Image Processing, Theory, Tools and Applications, Orleans, France, 337–340 (2015). <https://doi.org/10.1109/IPTA.2015.7367160>
- [107] I. T. Sitdikov and A. S. Krylov, “Variational image deringing using varying regularization parameter,” Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications, 25(1), 96–100 (2015). <https://doi.org/10.1134/S1054661815010186>
- [108] D. V. Sorokin, E. A. Arifulin, Y. S. Vassetzky, and E. V. Sheval, “Live-cell imaging and analysis of nuclear body mobility,” Methods in molecular biology (Clifton, N.J.), 2175, 1–9 (2020). https://doi.org/10.1007/978-1-0716-0763-3_1
- [109] D. V. Sorokin and A. S. Krylov, “Short reference image quality estimation using modified angular edge coherence,” in Proceedings of the 20th International Conference on Computer Graphics and Vision GraphiCon’2010, St. Petersburg, Russia, 137–140 (2010).
- [110] D. Sorokin and A. Krylov, “A projection local image descriptor,” Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications, 22(2), 380–385 (2012). <https://doi.org/10.1134/S1054661812020162>

- [111] D. V. Sorokin, M. M. Mizotin, and A. S. Krylov, “Gauss-Laguerre keypoints extraction using fast Hermite projection method,” *Lecture Notes in Computer Science*, 6753, 284–293 (2011). https://doi.org/10.1007/978-3-642-21593-3_29
- [112] D. V. Sorokin, I. Peterlik, M. Tektonidis, K. Rohr, and P. Matula, “Non-rigid contour-based registration of cell nuclei in 2D live cell microscopy images using a dynamic elasticity model,” *IEEE Transactions on Medical Imaging*, 37(1), 173–184 (2018). <https://doi.org/10.1109/TMI.2017.2734169>
- [113] D. Sorokin, I. Peterlík, V. Ulman, D. Svoboda, and M. Maška, “Model-based generation of synthetic 3D time-lapse sequences of motile cells with growing filopodia,” in *IEEE International Symposium on Biomedical Imaging: Nano to Macro (ISBI’2017)*, 822–826 (IEEE Melbourne, 2017). <https://doi.org/10.1109/ISBI.2017.7950644>
- [114] D. V. Sorokin, I. Peterlík, V. Ulman, D. Svoboda, T. Necasova, K. Morgaenko, L. Eiselleova, L. Tesarova, and M. Maška, “FiloGen: A model-based generator of synthetic 3D time-lapse sequences of single motile cells with growing and branching filopodia,” *IEEE Transactions on Medical Imaging*, 37(12), 2630–2641 (2018). <https://doi.org/10.1109/TMI.2018.2845884>
- [115] S. Stankovic, I. Orovic, and A. Krylov, “The two-dimensional Hermite S-method for high resolution ISAR imaging applications,” *IET Signal Processing*, 4(4), 352–362 (2010). <https://doi.org/10.1049/iet-spr.2009.0060>
- [116] S. Stankovic, I. Orovic, and A. Krylov, “Video frames reconstruction based on time-frequency analysis and Hermite projection method,” *Eurasip Journal on Advances in Signal Processing*, 1–11 (2011). <https://doi.org/10.1155/2010/970105>
- [117] M. Storozhilova, A. Lukin, D. Yurin, and V. Sinitsyn, “2.5D extension of neighborhood filters for noise reduction in 3D medical CT images,” *Lecture Notes in Computer Science*, 7870, 1–16 (2013). https://doi.org/10.1007/978-3-642-39759-2_1

- [118] G. Sun, B. Shi, X. Chen, A. S. Krylov, and Y. Ding, “Learning local quality-aware structures of salient regions for stereoscopic images via deep neural networks,” *IEEE Transactions on Multimedia*, 22(11), 2938–29491 (2020). <https://doi.org/10.1109/tmm.2020.2965461>
- [119] D. I. Sungatullina, A. S. Krylov, and D. N. Fedorov, “Fast registration algorithms for histological images,” *Scientific Visualization*, 6(4), 61–71 (2014).
- [120] A. S. Thomaz Aline, A. S. Lima Jonathan, C. J. Miosso, C. Q. Farias Mylene, A. S. Krylov, and Y. Ding, “Undersampled magnetic resonance image reconstructions based on a combination of U-Nets and L1, L2, and TV optimizations,” in *2022 IEEE International Conference on Imaging Systems and Techniques (IST)*, 1–6 (IEEE, 2022). <https://doi.org/10.1109/ist55454.2022.9827727>
- [121] V. Tikhonova and E. Pavelyeva, “Hybrid iris segmentation method based on CNN and principal curvatures,” in *CEUR Workshop Proceedings*, 2744, 1–10 (2020). <https://doi.org/10.51130/graphicon-2020-2-3-31>
- [122] A. V. Umnov and A. S. Krylov, “Sparse approach to image ringing detection and suppression,” *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 27(4), 754–762 (2017). <https://doi.org/10.1134/S1054661817040186>
- [123] A. V. Umnov, A. S. Krylov, and A. V. Nasonov, “Ringing artifact suppression using sparse representation,” *Lecture Notes in Computer Science*, 9386, 35–45 (2015). https://doi.org/10.1007/978-3-319-25903-1_4
- [124] A. Umnov, A. Nasonov, A. Krylov, and Y. Ding, “Sparse method for ringing artifact detection,” in *12th International Conference on Signal Processing (ICSP)*, Hangzhou, China, 662–667 (IEEE, 2014). <https://doi.org/10.1109/ICOSP.2014.7015086>

- [125] O. S. Volodina, A. Nasonov, and A. S. Krylov, “Choice of parameters in the weighted nuclear norm method for image denoising,” *Computational Mathematics and Modeling*, 31, 402–409 (2020). <https://doi.org/10.1007/s10598-020-09500-z>
- [126] A. Yatchenko and A. Krylov, “Cross-frame ultrasonic color Doppler flow heart image unwrapping,” in *Functional Imaging and Modeling of the Heart, FIMH 2015, Lecture Notes in Computer Science*, 9126, 265–272 (2015). https://doi.org/10.1007/978-3-319-20309-6_31
- [127] A. M. Yatchenko, A. S. Krylov, A. V. Gavrilov, and I. V. Arkhipov, “Graph-cut based antialiasing for doppler ultrasound color flow medical imaging,” in *IEEE International Conference Visual Communications and Image Processing*, Taiwan, 1–4 (2011). <https://doi.org/10.1109/VCIP.2011.6115923>
- [128] A. M. Yatchenko, A. S. Krylov, A. V. Gavrilov, and I. V. Arkhipov, “Building a three-dimensional dynamic model of left cardiac ventricle from ultrasonic data,” *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 22(3), 483–488 (2012). <https://doi.org/10.1134/S1054661812030091>
- [129] A. Yatchenko, A. Krylov, A. Gavrilov, V. Sandrikov, and T. Kulagina, “Image preprocessing for color Doppler flow antialiasing using power and complex phase data,” in *International Conference on Signal Processing Proceedings, ICSP*, Hangzhou, China, 1072–1076 (2014). <https://doi.org/10.1109/ICOSP.2014.7015168>
- [130] A. M. Yatchenko, A. S. Krylov, and A. V. Nasonov, “Deringing of MRI medical images,” *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 23(4), 541–546 (2013). <https://doi.org/10.1134/S1054661813040184>
- [131] A. M. Yatchenko, A. S. Krylov, V. A. Sandrikov, and T. Y. Kulagina, “Regularizing method for phase antialiasing in color Doppler flow mapping,” *Neurocomputing*, 139, 77–83 (2014). <https://doi.org/10.1016/j.neucom.2013.09.060>




Крылов Андрей Серджевич окончил Московский государственный университет имени М.В. Ломоносова в 1978 году, получил степень кандидата и доктора наук по прикладной математике в Московском государственном университете имени М.В. Ломоносова в 1983 и 2009 годах соответственно. С 1978 года работает на факультете вычислительной математики и кибернетики МГУ им. М.В. Ломоносова. Сейчас он профессор, заведующий лабораторией математических методов обработки изображений. Главный редактор журнала *Springer Computational Mathematics and Modeling* с 2020 г. В 2016–2021 гг. член программных комитетов более 45 международных конференций. Он был удостоен премии Ленинского комсомола в области науки и техники в 1989 году. Его научные интересы включают математические методы обработки изображений и компьютерное зрение.



Насонов Андрей Владимирович в 2007 году окончил Московский государственный университет имени М.В. Ломоносова, а в 2011 году получил степень кандидата наук по прикладной математике в Московском государственном университете имени М.В. Ломоносова. Сейчас он старший научный сотрудник лаборатории математических методов обработки изображений факультета вычислительной математики и кибернетики МГУ имени М.В. Ломоносова. Область его научных интересов включает математические методы обработки и анализа изображений, регуляризирующие методы.



Сорокин Дмитрий Васильевич окончил Московский государственный университет имени М.В. Ломоносова и получил степень кандидата наук в области прикладной математики в Московском государственном университете имени М.В. Ломоносова в 2008 и 2011 годах соответственно. С 2012 по 2017 год он был постдок-исследователем в Центре биомедицинского анализа изображений Университета Масарика, Брно, Чешская Республика. С 2018 года работает на факультете вычислительной математики и кибернетики МГУ имени М.В. Ломоносова в должности старшего научного сотрудника лаборатории математических методов обработки изображений. В 2018 году награжден премией Правительства Москвы для молодых ученых. Он является членом программных комитетов нескольких ежегодных международных конференций и выступает в качестве рецензента IEEE Transaction of Medical Imaging. Его научные интересы включают математические методы обработки и анализа изображений, совмещение изображений, анализ биомедицинских изображений, глубокое обучение.



Хвостиков Александр Владимирович окончил Московский государственный университет имени М.В. Ломоносова в 2015 году и получил степень кандидата наук в области прикладной математики в Московском государственном университете имени М.В. Ломоносова в 2019 году. С тех пор работает на факультете вычислительной математики и кибернетики МГУ имени М.В. Ломоносова. Является научным сотрудником лаборатории математических методов обработки изображений. В 2020 году удостоен премии МГУ имени М.В. Ломоносова для молодых преподавателей и

исследователей, добившихся значительных результатов в преподавательской и научно-исследовательской деятельности. Его научные интересы включают обработку изображений и анализ медицинских изображений, компьютерное зрение, машинное обучение, глубокое обучение, сверточные нейронные сети, гибридные методы.



Павельева Елена Александровна окончила Московский государственный университет имени М.В. Ломоносова в 2008 году, получила степень кандидата наук в области прикладной математики в Московском государственном университете имени М.В. Ломоносова в 2015 году. В настоящее время работает в должности

старшего преподавателя на факультете вычислительной математики и кибернетики МГУ имени М.В. Ломоносова. Ее научные интересы включают обработку и анализ изображений, биометрию, компьютерное зрение.



Пчелинцев Яков Александрович получил степень бакалавра и магистра в области прикладной математики и информатики в МГУ имени М.В. Ломоносова в 2017 и 2019 годах соответственно. Сейчас является аспирантом факультета вычислительной математики и кибернетики МГУ имени М.В. Ломоносова в лаборатории

математических методов обработки изображений. Его научные интересы включают обработку и анализ изображений, машинное обучение, глубокое обучение, сверточные нейронные сети, гибридные методы.