

**X конференция по математическим моделям и численным методам  
в биологии и медицине**

# Персонализация модели сердца по данным томографии пациента

с помощью методов глубокого обучения и специализированного метода CPD

**Лачинов Дмитрий Александрович, [dlachinov@gmail.com](mailto:dlachinov@gmail.com);**  
Васильев Е.П., Воеводин А.М., Турлапов В.Е.

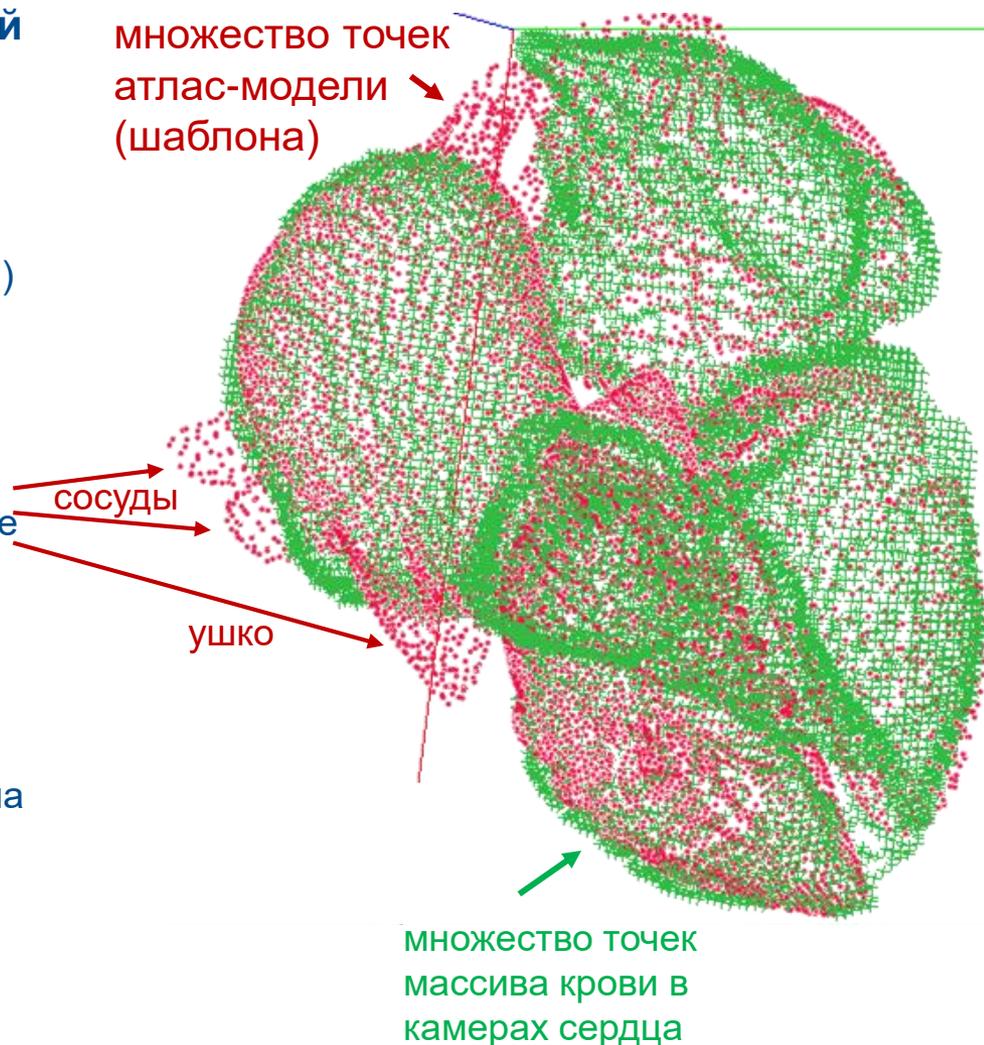
# Задача

## ▪ Персонализация конечноэлементной модели по данным томографии

- Извлечение информации из томограммы пациента
- Совмещение шаблона (атлас-модели) сердца с данными томографии

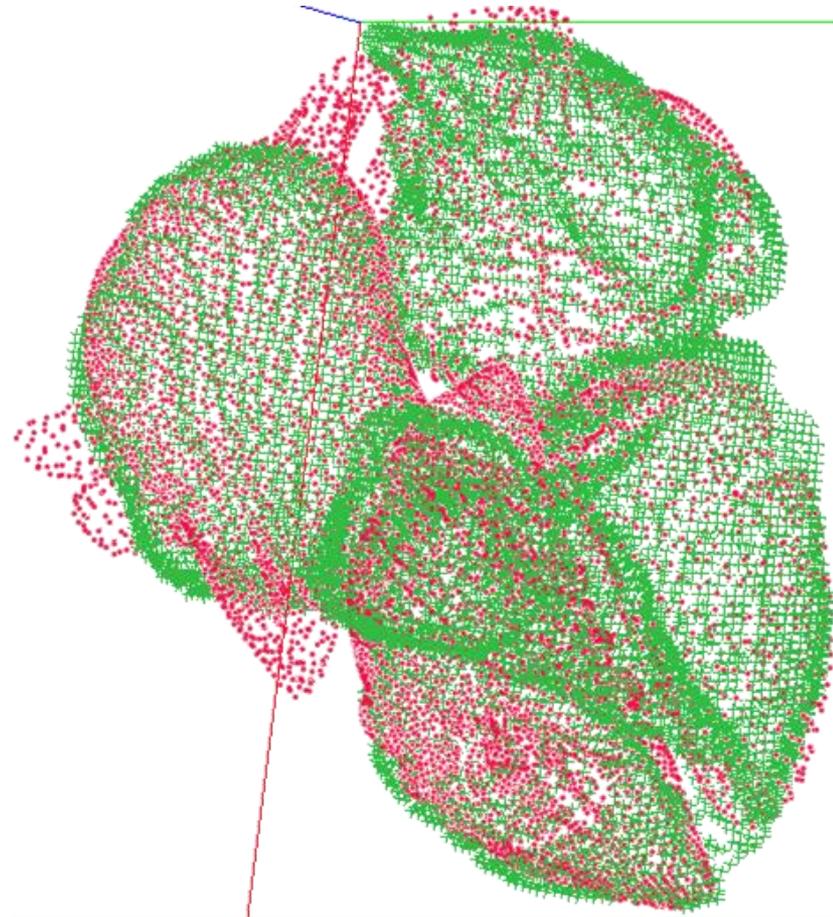
## ▪ Проблемы

- Шаблон содержит дополнительные детали, неразличимые на томограмме
- В общем случае, не существует однозначного отображения
- Высокий уровень шумов
- Частое нарушение структуры шаблона



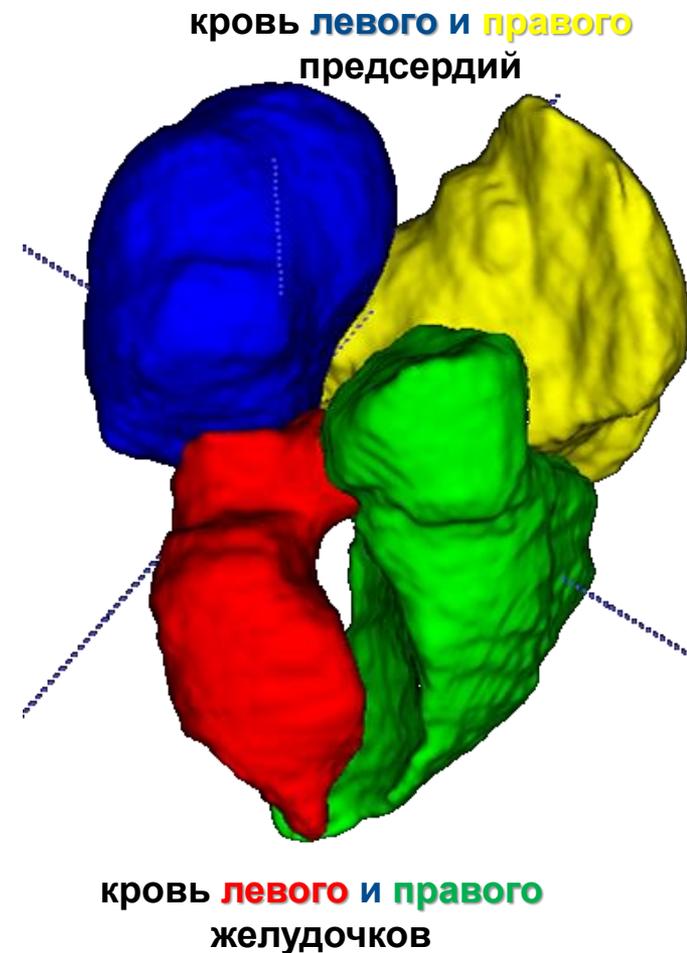
# Метод решения задачи персонализации

- Извлечение информации из данных томографии пациента
  - **Сегментация объемов крови** предсердий и желудочков
  - Извлечение внутренней поверхности предсердий и желудочков из сегментации
- **Нежесткое совмещение** готовой 3D атлас-модели (3D шаблона) сердца с данными томографии пациента



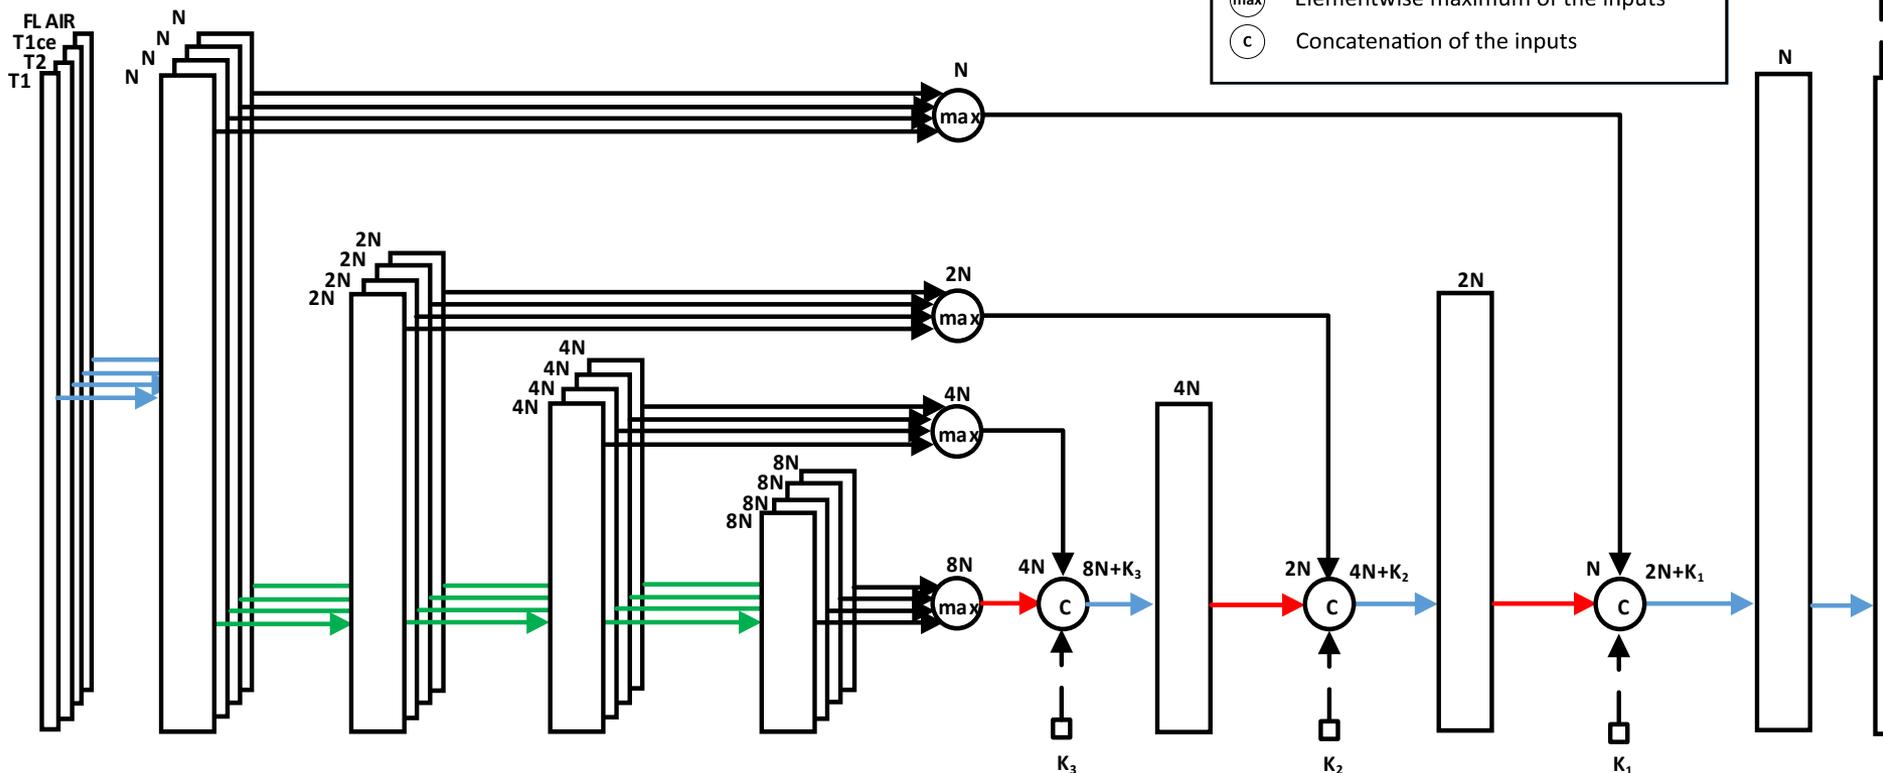
# Сегментация

- **Выделение объемов предсердий и желудочков по контрастированной крови**
  - Выполняется при помощи методов глубокого обучения
  - Высокая точность и надежность сегментации крови в связи с ее контрастированием
  - Применима к КТ-данным с высоким уровнем шума
- **Предобработка**
  - Приведение данных к одному пространственному разрешению 1x1x1 мм
  - Выделение диапазона крови по шкале Хаунсфилда
  - Z-score нормализация выделенного диапазона
  - Приравнивание оставшихся вокселей к минимуму из выделенного диапазона
- **Данные для обучения**
  - BraTS 2018 - для предобучения
  - MMWHS 2017 - для обучения



# Сегментация. Метод глубокого обучения

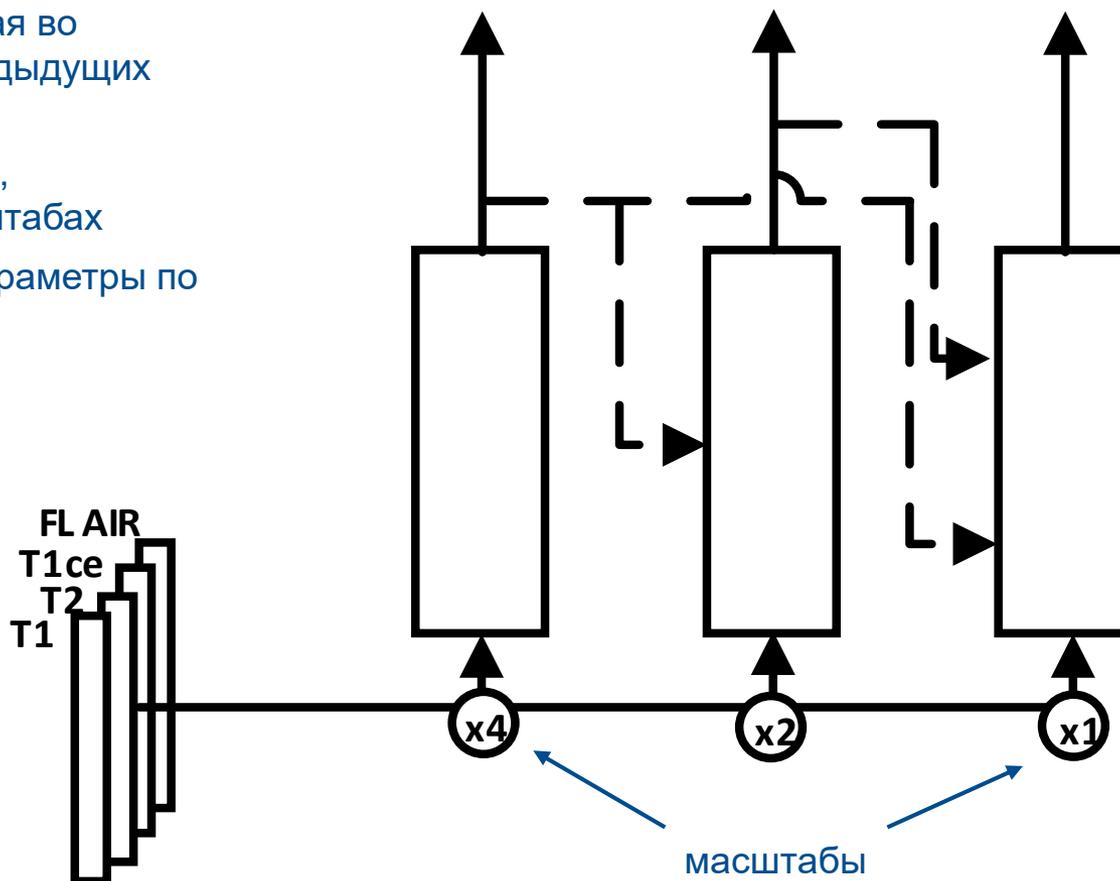
- Модификация U-net, состоящая в использовании одновременно нескольких входов данных согласно схеме
- Допускает мультимодальный вход (в т.ч. мультимодальные MRI данные)
- Итеративно улучшает результат



# Сегментация. Метод глубокого обучения (2)

## Итеративное улучшение результата

- Каждая модель порождает сегментацию на своем масштабе, принимая во внимание результаты на предыдущих масштабах
- Объединяет несколько сетей, работающих на разных масштабах
- Эффективней использует параметры по сравнению с одной моделью



# Сегментация. Результаты

## Качество сети, разработанной для глубокого обучения:

В десятке лучших в соревновании по сегментации опухолей мозга BraTS 2018 (см. табл.)

Метрика:  $DSC = \frac{2TP}{2TP+FP+FN}$

ID	BraTS 2018 Val.		
	ET	WT	TC
UNet	0.779	0.901	0.837
ME UNet	0.784	0.907	0.827
C ME UNet	0.784	0.908	0.844

ID	BraTS 2018 Test.		
	ET	WT	TC
First	0.766	0.883	0.815
Second	0.778	0.878	0.806
Ours	0.720	0.878	0.795

## Качество сегментации, показанное методом на данных сердец MMWHS 2017 CV

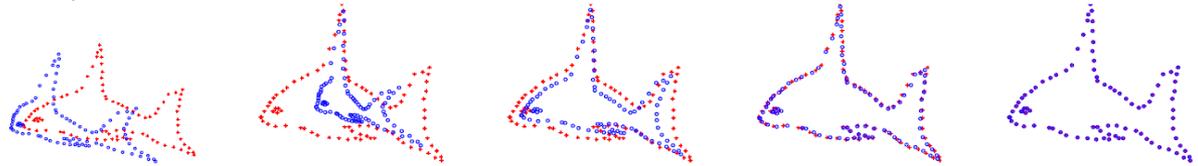
ID	MMWHS 2017 CV			
	LV	RV	LA	RA
C UNet	0.864	0.780	0.834	0.802

LV, RV, LA, RA – левый и правый желудочки и предсердия соответственно

# Нежесткое совмещение множества точек шаблона $Y$ с множеством сегментированных точек $X$

**Метод:** Coherent Point Drift (CPD) [1].

Пример. Показаны 0, 10, 20, 40, 50 итерации совмещения шаблона  $Y$  (синий) с данными  $X$  (красный).



**Свойство  $Y$ :** Положение каждой из точек множества  $Y$  управляется распределением Гаусса.

**Соответствие между  $Y$  и  $X$ :** Соответствие между точками целевого множества  $X$  и каждой из точек шаблона  $Y$  устанавливается на каждой итерации по критерию (1)

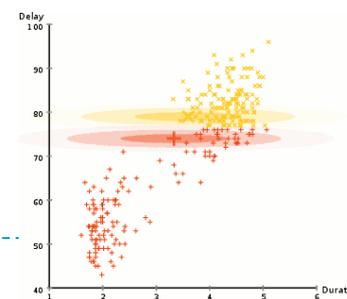
$$X[i] \sim Y \left[ \operatorname{argmax}_j P(i, j) \right], \text{ где } p_{ij} = \frac{e^{-\frac{1}{2\sigma^2} \|y_j^{old} - x_i\|^2}}{\sum_{j=1}^M e^{-\frac{1}{2\sigma^2} \|y_j^{old} - x_i\|^2}} \quad (1)$$

$p_{ij}$  – элементы матрицы апостериорных вероятностей,  $y_j^{old}$  – результат предыдущей итерации.

CPD основан на алгоритме EM (Expectation Maximization) и является вероятностным итерационным алгоритмом. Гауссовские центры подстраиваются (в пределах  $3\sigma$ ) под данные пациента, тем самым максимизируя функцию правдоподобия и уменьшая  $\sigma$  с каждой итерацией.

[1] Andriy Myronenko, Xubo Song. Point-Set Registration: Coherent Point Drift. 2009. <https://arxiv.org/abs/0905.2635>

# Содержание метода CPD



(2)

Итерация  $Y$  определяется как:  $Y = GW + Y_0$

$W = (w_1, w_2, \dots, w_m)^T$  - матрица весов,

$G$  - матрица Грамма с элементами  $g_{ij} = e^{-\frac{1}{2\beta^2}\|y_{0i}-y_{0j}\|^2}$  (Gaussian proximity between  $Y$ - elements)

$$(diag(P \cdot \mathbf{1})G + \lambda\sigma^2 I)W = PX - diag(P \cdot \mathbf{1})Y_0, \quad (3)$$

где  $\mathbf{1}$  – вектор единиц длины  $N$ ;  $P$  – матрица апостериорных вероятностей уточняемая на каждой итерации.

## Преимущества CPD:

- Нежесткий и быстрый жесткий процессы совмещения (регистрации), с возможностями превосходящими другие алгоритмы регистрации
- Существует возможность быстрой реализации на основе алгоритма быстрого преобразования Гаусса (L. Greengard and J. Strain, “The fast gauss transform,” SIAM JSSC, vol. 12, no. 1, pp. 79–94, 1991) и другие возможности ускорения вычислений.
- Имеется Matlab-код CPD свободный для научных исследований.

## Недостатки CPD:

Существуют проблемы для регистрации трехмерных множеств в случае существенной разницы в ориентации начальных положений множеств и наличия в них мелких деталей

# Новый метод Cluster Coherent Point Drift (CCPD), повышающий устойчивость алгоритма

Cluster Coherent Point Drift в отличие от CPD использует априорную информацию о принадлежности к одному из кластеров ( $c$ ):

$$\tilde{p}(x) = \sum_{c=1}^{C+1} P(c) \sum_{m=1}^{M+1} p(x|m, c)P(m|c) = \sum_{c=1}^{C+1} P(c) \sum_{m=1}^{M+1} \frac{p(x|m)P(m|c)P(c|x, m)}{P(c|m)}$$

В сравнении с Gaussian mixture model (GMM) центроидов

$Y$  с номером  $m$  в методе CPD:

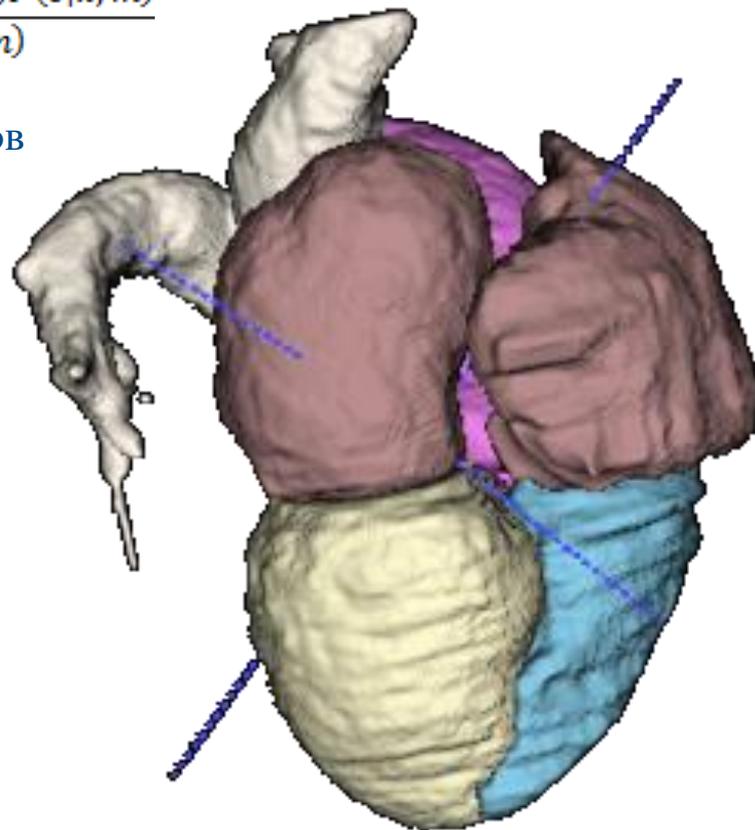
$$p(x) = \sum_{m=0}^{M+1} p(x|m)P(m)$$

Регуляризация для создания когерентного движения:

$$f(v, \sigma^2) = E(v, \sigma^2) + \frac{\lambda}{2} \phi(v)$$

$$\phi(v) = \|v\|_{H_m}^2 = \|Pv\|^2$$

$v(Y)$  – функция перемещения, согласно [1].



# Тестирование нового метода нежесткого совмещения на фоне аналогов

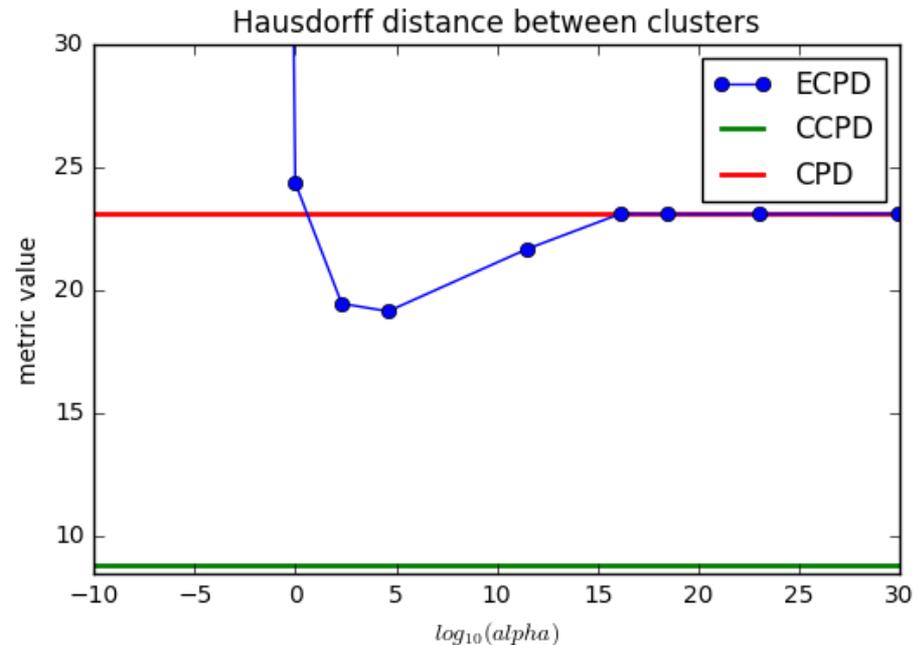
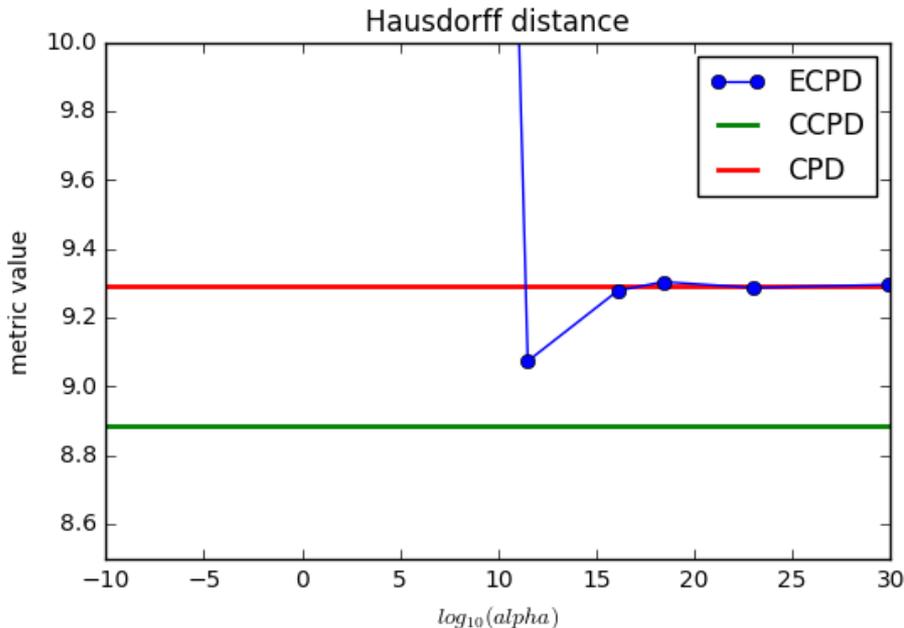
Тестируемые методы: ECPD - Extended Coherent Point Drift Algorithm (2016); CCPD - Cluster Coherent Point Drift; CPD - Coherent Point Drift (2009)

Использована метрика: Hausdorff distance

$$h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\|$$

$$H(A, B) = \max(h(A, B), h(B, A))$$

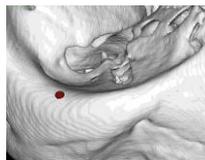
$$HC(A, B) = \frac{1}{C} \sum_{c=1}^C \max(h(A(c), B(c)), h(B(c), A(c)))$$



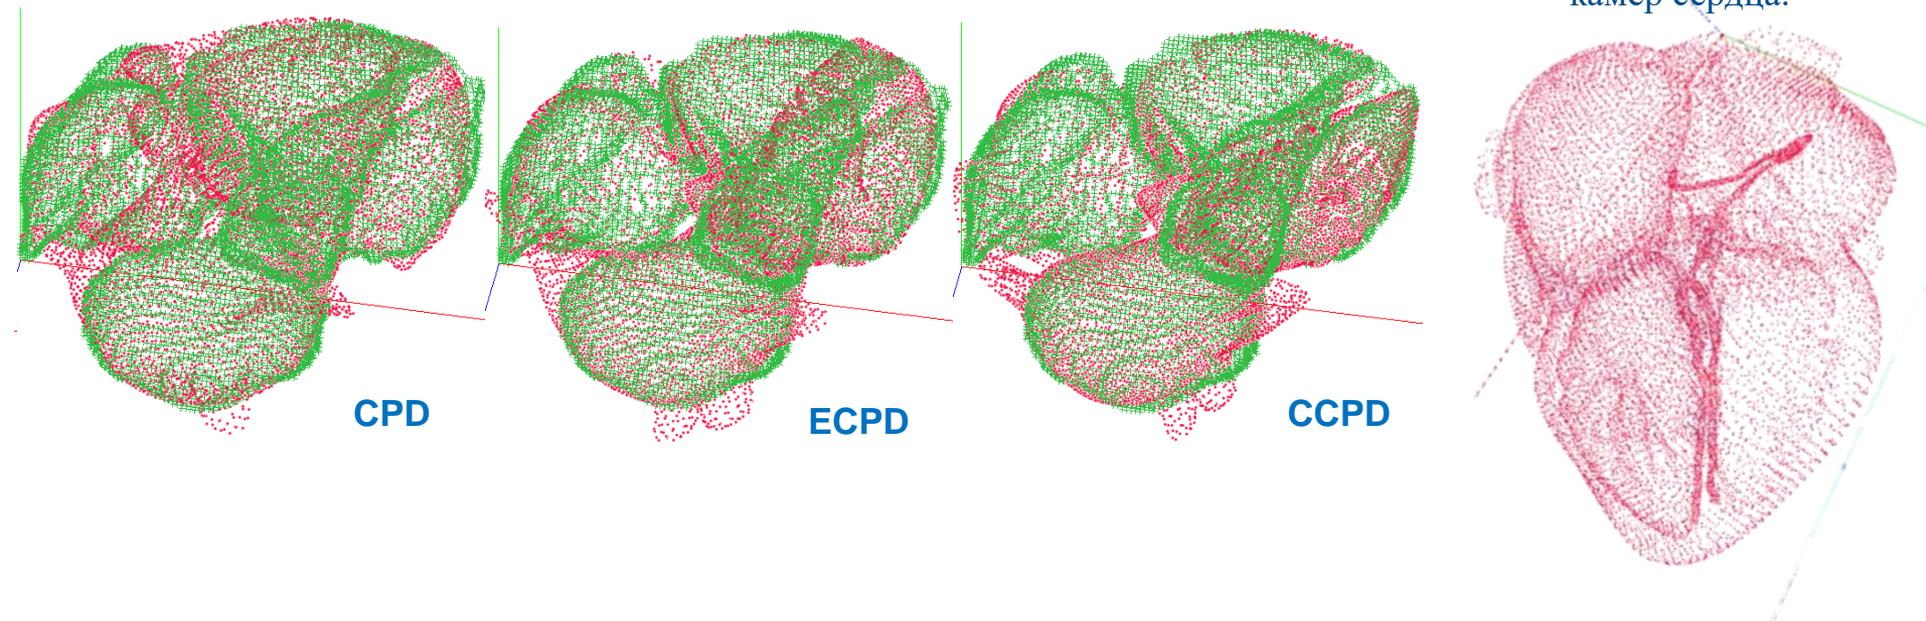
# Результаты совмещения методом CCPD

## Преимущества CCPD:

- Получено с учетом априорной информации о сегментации камер сердца
- Более устойчиво к начальному приближению и сохраняет макроструктуру шаблона Y
- Применимо к широкому кругу задач



Совмещение миокарда атлас-модели как начальное приближение по результатам совмещения контрастированной крови камер сердца.



# Заключение

---

- 1) Предложена процедура персонализации готовой геометрической атлас-модели сердца  $Y$  (в том числе конечноэлементной), основанная на сегментации камер сердца по массиву контрастированной крови  $X$  на данных томографии пациента, с последующим нежестким совмещением  $Y$  с массивом  $X$ .
- 2) Для обеспечения автоматизации сегментации камер сердца по контрастированной крови построена специальная модификация Unet, которая предобучена на массиве размеченных данных BraTS 2018 и дообучена на размеченном массиве томограмм сердец MMWHS 2017
- 3) Разработана модификация метода CPD, Cluster Coherent Point Drift (CCPD), имеющая более высокую устойчивость к исходным данным за счет учета результата сегментации камер.
- 4) Совмещение миокарда атлас-модели выполняется как начальное приближение по результатам совмещения контрастированной крови камер сердца.

## Публикации на ресурсе ArXiv:

- 1) Dmitry Lachinov, Evgeny Vasiliev, and Vadim Turlapov. Glioma Segmentation with Cascaded Unet (2018): <https://arxiv.org/abs/1810.04008>
- 2) Dmitry Lachinov, and Vadim Turlapov. Coherent Point Drift for Clustered Point Sets: preprint will be available on arxiv soon

