

**ЭФФЕКТИВНОЕ 3D ВОССТАНОВЛЕНИЕ  
МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ С МАЛЫМ ЧИСЛОМ  
ПРОЕКЦИЙ НА ОСНОВЕ 2D ДИФФУЗИОННЫХ  
МОДЕЛЕЙ С АПРИОРАМИ КРИВИЗНЫ**

**Чжоу Цин**

*Студент*

*Факультет ВМК МГУ имени М. В. Ломоносова, Москва, Россия*

*E-mail: zhouqing@cs.msu.ru*

**Научный руководитель** — *Терновский Владимир Владимирович*

Реконструкция медицинских изображений из частичных измерений - важная обратная задача в КТ и МРТ. Существующие модели диффузии эффективны для 2D, но применимы к 3D с высокой вычислительной стоимостью. В этой работе предложен метод 3D реконструкции из редких видов, использующий предварительно обученные 2D модели диффузии и регуляризацию кривизны. Метод сочетает итеративную реконструкцию с ADMM и шаги денойзинга моделей диффузии. Регуляризация кривизны улучшает согласованность реконструкции вдоль оси  $z$ . Эксперименты показали улучшения в сохранении деталей и структурной целостности при ограниченных углах КТ, с повышением PSNR и SSIM на 15% по сравнению с базовыми методами.

Для реконструкции используется обратный процесс 2D модели диффузии, который восстанавливает изображение, минимизируя разницу между добавленным шумом и истинными данными.

$$d\mathbf{x} \simeq -\frac{d[\sigma^2(t)]}{dt} s_{\theta}^*(\mathbf{x}(t), t) dt + \sqrt{\frac{d[\sigma^2(t)]}{dt}} d\bar{\mathbf{w}}. \quad (1)$$

где  $s_{\theta}^*(\mathbf{x}(t), t)$  — это обученная нейронная сеть, которая оценивает остаточный шум на каждом шаге времени.

Медицинские системы визуализации, моделируются с использованием линейного прямого уравнения:

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{n}, \quad (2)$$

где  $\mathbf{y} \in \mathbb{R}^m$  представляет измеренные данные,  $\mathbf{x} \in \mathbb{R}^n$  — это изображение, которое нужно восстановить,  $\mathbf{A} \in \mathbb{R}^{m \times n}$  — это матрица преобразования системы, а  $\mathbf{n}$  обозначает шум измерений.

Задача оптимизации формулируется как:

$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{u}\|_2^2 + \mathcal{R}(\kappa(\mathbf{u})) \right\}, \quad (3)$$

где  $\mathcal{R}(\kappa(\mathbf{u}))$  — это регуляризационный член кривизны, а  $\kappa$  представляет среднюю кривизну. Конкретно:  $\mathcal{R}(\kappa(\mathbf{u})) = \lambda \int_{\Omega} g(\kappa) |\nabla \mathbf{u}| \, d\mathbf{x}$ ,  $g(\kappa)$  — функция, зависящая от кривизны, для примера мы возьмем ТАС ( $g(\kappa) = (1 + \alpha|\kappa|)$ ).

Для решения задачи минимизации с регуляризацией кривизны используется метод ADMM. Вводим вспомогательные переменные  $\mathbf{v}$  и  $\mathbf{w}$ :

$$\begin{cases} \min_{\mathbf{u}, \mathbf{v}, \mathbf{w}} \frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{u}\|_2^2 + \lambda \int_{\Omega} (1 + \alpha|\kappa|) |\mathbf{w}| \, d\mathbf{x}, \\ \text{subject to } \mathbf{v} = \nabla \mathbf{u}, \quad \mathbf{w} = \mathbf{v}. \end{cases} \quad (4)$$

Аугментированная функция Лагранжа:

$$\begin{aligned} L(\mathbf{u}, \mathbf{v}, \mathbf{w}) &= \frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{u}\|_2^2 + \lambda \int_{\Omega} (1 + \alpha|\kappa|) |\mathbf{w}| \, d\mathbf{x} \\ &+ \mathbf{p}^T (\mathbf{v} - \nabla \mathbf{u}) + \frac{\mu}{2} \|\mathbf{v} - \nabla \mathbf{u}\|_2^2 \\ &+ \mathbf{q}^T (\mathbf{w} - \mathbf{v}) + \frac{\eta}{2} \|\mathbf{w} - \mathbf{v}\|_2^2. \end{aligned} \quad (5)$$

1. Обновление  $\mathbf{u}, \mathbf{v}$  и  $\mathbf{w}$ :

$$\mathbf{u}^{k+1} = (\mathbf{A}^T \mathbf{A} + \mu \nabla^T \nabla)^{-1} \left( \mathbf{A}^T \mathbf{y} + \mu \nabla^T \left( \mathbf{v}^k + \frac{\mathbf{p}^k}{\mu} \right) \right). \quad (6)$$


$$\mathbf{v}^{k+1} = \frac{\mu \left( \nabla \mathbf{u}^{k+1} - \frac{\mathbf{p}^k}{\mu} \right) + \eta \left( \mathbf{w}^k + \frac{\mathbf{q}^k}{\eta} \right)}{\mu + \eta}. \quad (7)$$

$$\mathbf{w}^{k+1} = \mathcal{S}_{\frac{\lambda(1+\alpha|\kappa|)}{\eta}} \left( \mathbf{v}^{k+1} - \frac{\mathbf{q}^k}{\eta} \right), \quad \mathcal{S}_{\tau}(z) = \frac{z}{|z|} \max(|z| - \tau, 0). \quad (8)$$

2. Обновление множителей Лагранжа:

$$\begin{aligned} \mathbf{p}^{k+1} &= \mathbf{p}^k + \mu (\mathbf{v}^{k+1} - \nabla \mathbf{u}^{k+1}), \\ \mathbf{q}^{k+1} &= \mathbf{q}^k + \eta (\mathbf{w}^{k+1} - \mathbf{v}^{k+1}). \end{aligned} \quad (9)$$

## Иллюстрации



Результаты реконструкции на наборе данных LDCT с 8 видами: аксиальные, сагитальные и коронарные срезы, с использованием различных методов регуляризации кривизны.

## Литература

1. Yang Song, Jascha Sohl-Dickstein, Diederik P. Kingma, Abhishek Kumar, Stefano Ermon, and Ben Poole. “Score-based generative modeling through stochastic differential equations.” In 9th International Conference on Learning Representations, ICLR, 2021.
2. L. Liu, “Model-based iterative reconstruction: a promising algorithm for today’s computed tomography imaging,” *Journal of Medical Imaging and Radiation Sciences*, vol. 45, no. 2, pp. 131–136, 2014.
3. Chambolle and T. Pock, “Total roto-translational variation,” *Numerische Mathematik*, vol. 142, pp. 611–666, 2019.
4. Y. Liu, F. Shang, H. Liu, L. Kong, L. Jiao, and Z. Lin, “Accelerated variance reduction stochastic admn for large-scale machine learning,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 43, no. 12, pp. 4242–4255, 2020.
5. C. H. McCollough, A. C. Bartley, R. E. Carter, B. Chen, T. A. Drees, P. Edwards, D. R. Holmes III, A. E. Huang, F. Khan, S. Leng et al., “Low-dose CT for the detection and classification of metastatic liver lesions: results of the 2016 low dose CT grand challenge,” *Medical Physics*, vol. 44, no. 10, pp. e339–e352, 2017.