

УДК 519.6+004.891.3+616-018

## НЕЙРОСЕТЕВОЙ МЕТОД ДЕТЕКТИРОВАНИЯ РАЗМЫТИЯ НА ГИСТОЛОГИЧЕСКИХ ИЗОБРАЖЕНИЯХ

© 2024 г. Г. С. Назаренко<sup>а,\*</sup>, А. С. Крылов<sup>а,\*\*</sup><sup>а</sup>Московский государственный университет имени М.В. Ломоносова  
119991 Москва, ГСП-1, Ленинские горы, д. 1

\*E-mail: s02190303@gse.cs.msu.ru

\*\*E-mail: kryl@cs.msu.ru

Поступила в редакцию 15.01.2024 г.

После доработки 19.01.2024 г.

Принята к публикации 24.01.2024 г.

В работе рассматривается задача обнаружения размытых областей на полнослайдовых гистологических изображениях высокого разрешения. Предлагаемый метод основан на использовании нейронного оператора Фурье, обучаемого на результатах двух одновременно использованных подходов: обнаружения размытия с помощью многомасштабного анализа коэффициентов дискретного косинусного преобразования и оценки степени резкости границ объектов на изображениях. Эффективность алгоритма подтверждена на изображениях из наборов данных PATH-DT-MSU [1] и FocusPath [2].

**Ключевые слова:** гистология, глубокое обучение, область размытия, нейронный оператор Фурье

**DOI:** 10.31857/S0132347424030075, **EDN:** QAGUUM

### 1. ВВЕДЕНИЕ

Современная гистопатологическая диагностика включает в себя извлечение образцов тканей и проведение гистотехнических процедур для подготовки оцифрованного предметного стекла, называемого полнослайдовым изображением (WSI), для дальнейшего исследования. Неправильное обращение с образцом ткани может привести к появлению артефактов (областей, не имеющих диагностического значения, поскольку внешний вид ткани изменен или поврежден) в полученном WSI [26], что может влиять на системы вычислительной патологии и на поставленный диагноз, если их не исключить или не обработать. Недавние работы по WSI с использованием методов глубокого обучения для диагностического прогнозирования в основном основывались на ручном выборе областей интереса (ROI) без артефактов, имеющих диагностическую значимость [27]. Однако ручной выбор трудоемок и требует много времени. И, поскольку артефакты, включенные во время обучения или вывода, могут ухудшить результаты прогнозирования, то необходимо разрабатывать алгоритмы и программы по автоматическому обнаружению артефактов.

Одним из наиболее часто встречающихся является артефакт размытия изображений, воз-

никающий при смещении фокуса (т.е. профиля сканирования) во время сканирования предметных стекол [28, 29]. Два основных подхода оценки уровня размытия областей гистологических изображений основаны на использовании классических математических методов или методов глубокого обучения. Используя подход, основанный на DCNN, в работе [30] были обучены семь современных архитектур на наборе данных FocusPath<sup>1</sup> [25] и было проведено сравнение результатов с классическими методами. DeepFocus [31] использовал аналогичный подход с CNN для анализа размытых областей в WSI с различными красителями. Другие системы оценки качества фокуса, такие как ConvFocus [32] и FocusLiteNN [33], использовали модели на основе CNN для количественной оценки и локализации размытых областей в WSI. В работе [34] предложен метод, основанный на глубоком ядерном обучении, проанализированный, наряду с оригинальными наборами, также на наборах данных FocusPath [25] и TCGA [33].

При анализе результатов на конкретных наборах данных несомненное преимущество имеют методы глубокого обучения. В то же время хорошо известна проблема плохой устойчивости

<sup>1</sup> <https://sites.google.com/view/focuspathuoft>

результатов, возникающая при использовании нейросетевых моделей на отличающихся наборах данных, например, при использовании данных, полученных другими сканерами. В связи с этим несомненный интерес представляют нейросетевые методы, основанные, в том числе, на использовании классических моделей — “нейросетевые методы, основанные на физике” (PINN) [35]. В настоящее время по близкой к PINN тематике в задаче размытия гистологических изображений нам известна только статья [36]. В данной работе нами рассмотрен метод PINN, основанный на использовании нейросетевого оператора Фурье (FNO) и базирующийся на классических методах оценки размытия [37, 38] для задачи бинарной классификации уровня размытия гистологических изображений. Структура статьи включает в себя введение, раздел описывающий моделируемый классический метод, краткое описание нейросетевого оператора Фурье и параметры оператора, выбранные для моделирования, результаты работы алгоритма и заключение.

## 2. ИСПОЛЬЗУЕМЫЙ КЛАССИЧЕСКИЙ АЛГОРИТМ

Моделируемый классический метод поиска размытых фрагментов на гистологических изображениях состоит из следующих этапов:

1. Построение карты размытия с помощью применения высокочастотного многомасштабного преобразования [37].
2. Оценка степени резкости изображения на основе анализа границ объектов [38].
3. Объединение полученных результатов и детекция размытых областей.




Рис. 1. График отсортированных по возрастанию абсолютных значений коэффициентов ДКП для размытых и четких фрагментов гистологических изображений.

### 2.1. Высокочастотное многомасштабное преобразование

Дискретное косинусное преобразование (ДКП) — это преобразование, которое преобразует сигнал (или в данном случае изображение) из пространственного представления в частотное. Широко известно, что размытие приводит к уменьшению амплитуд высокочастотных коэффициентов ДКП изображения. На рис. 1 приведен график отсортированных по возрастанию абсолютных значений амплитуд высокочастотных коэффициентов ДКП для резких и размытых участков гистологических изображений, демонстрирующий заметную разницу в их значениях. Все последующие шаги описываемого подхода основаны на этом различии.


Обозначим через  $I$  входное изображение в градациях серого размером  $N_1 \times N_2$  пикселей. Через  $P_{i,j}^M$  обозначим фрагмент (патч) изображения  $I$  размером  $2M + 1 \times 2M + 1$  с центром в пикселе  $(i, j)$ , а через  $K_{i,j}^M$  — результат применения к  $P_{i,j}^M$  ДКП:

$$K_{i,j}^M(u, v) = \frac{c(u)c(v)}{2M+1} \sum_{s=0}^{2M} \sum_{t=0}^{2M} P_{i,j}^M(s, t) S^M(s, u, t, v);$$

$$S^M(s, u, t, v) = \cos\left(\frac{\pi(2s+1)u}{2(2M+1)}\right) \cos\left(\frac{\pi(2t+1)v}{2(2M+1)}\right); \quad (1)$$

$$c(p) = \begin{cases} 1, & p = 0 \\ \sqrt{2}, & p \neq 0 \end{cases}, \text{ где } p - \text{переменная.}$$

В предложенном преобразовании вычисленные коэффициенты ДКП для каждого патча делятся на три группы, а именно, на соответ-






Рис. 2. Иллюстрация коэффициентов ДКП для блока при их разделении на группы соответствия различным частотам.

ствующие низким, средним и высоким частотам [39]. Рис. 2 иллюстрирует эти три группы коэффициентов на примере патча размером  $7 \times 7$  пикселей.

Обозначим через  $H_{i,j}^M$  вектор, состоящий из модулей высокочастотных коэффициентов ДКП  $H_{i,j}^M$  патча:

$$H_{i,j}^M = \left\{ \left| K_{i,j}^M(u,v) \right| : u+v \geq 2M, 0 \leq u,v \leq 2M \right\}. \quad (2)$$

Рассмотрение только одного разрешения (размера патча) может оказаться недостаточным для определения размытия на изображении. Проблема выбора количества разрешений обсуждалась в [40, 41]. В этих работах было высказано предположение о том, что человеческая зрительная система при определении различных объектов на изображении достаточно сложным образом использует информацию с различных разрешений. В связи с этим было предложено решать поставленную задачу сразу для нескольких размеров патчей, а затем агрегировать полученные результаты следующим образом:

$$L_{i,j} = \text{sort} \left( \bigcup_{r=0}^m H_{i,j}^{M_r} \right), \quad (3)$$

где  $H_{i,j}^{M_r}$  патч размером  $2M_r + 1 \times 2M_r$  ( $M_r = 2^r$ ), а  $\bigcup_{r=0}^m H_{i,j}^{M_r}$  означает объединение модулей высокочастотных коэффициентов ДКП, взятых со всех  $m + 1$  разрешений. Таким образом,  $L_{i,j}$  является вектором размерности

$\sum_{r=0}^m \frac{(2M_r + 1)^2 + 2M_r + 1}{2}$ , но исходя из наблюдений достаточно использовать лишь первые  $\sum_{r=0}^m (2M_r + 1)$  [37] компонентов для оптимизации времени работы метода.

Пусть  $L_{i,j;t}$  —  $t$ -й элемент вектора  $L_{i,j}$ , а  $L_t$  —  $t$ -й слой, образованный путем взятия  $L_{i,j;t}$  элемента во всех векторах  $L_{i,j}$  каждого пиксела  $(i, j)$  изображения  $I$ . Размерность  $L_t$  совпадает с размерностью исходного изображения.

Результатом предложенного высокочастотного многомасштабного преобразования являются слои  $L_t$ , которые далее min-max нормализуются [37]. По мере увеличения номера слоя, слои начинают состоять из больших по абсолютному значению высокочастотных коэффициентов, тем самым все больше структур и границ объектов исходного изображения появляется на слоях.

## 2.2. Построение карты размытия

К входному изображению в градациях серого  $I$  применяется Гауссов фильтр с параметром  $\sigma = 0.5$  для подавления высокочастотного шума. Обозначим отфильтрованное изображение  $I$  за  $I_g$ . Далее для  $I_g$  вычисляется карта величин градиентов  $G$  следующим образом:

$$G = \sqrt{(I_g h_x)^2 + (I_g h_y)^2}, \quad (4)$$

где

$$h_x = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \text{ и } h_y = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}.$$

Для карты градиентов  $G$  вычисляются слои  $L_t$  по формулам (1)–(3). В результате искомая карта размытия изображения рассчитывается как

$$D_{i,j} = \max \left\{ \left\{ \tilde{L}_t(i,j) : t = 1, \dots, \sum_{r=1}^m M_r \right\} \right\}; \quad (5)$$

$$0 \leq i < N_1, 0 \leq j < N_2.$$

Окончательная карта размытия  $D$  сглаживается с помощью фильтра [42]. На рис. 3 приведен пример карты размытия. Чем темнее область на карте размытия, тем сильнее размыта эта область на исходном изображении.

## 3. ОЦЕНКА РЕЗКОСТИ ИЗОБРАЖЕНИЯ

Границей объекта на изображении (edge) называется область неоднородности или область перехода между двумя различными по интенсивности областями изображения.





Рис. 3. Визуализация карты размытия для гистологического изображения с отмеченными красным областями размытия.

Оценка резкости изображения  $S_I$  вычисляется на основании оценки размытия вдоль границ объектов на изображении. В оригинальной статье [38] рассматривались лишь горизонтальные и вертикальные границы изображения, однако в данной работе было принято решение рассмотреть, в том числе и диагональные границы.

Более подробно об оценке можно прочесть в оригинальной статье [38], а о ее модификации — в работе [44].

#### 4. ОБЩИЙ АЛГОРИТМ КЛАССИЧЕСКОГО МЕТОДА

Дано входное изображение  $I$ . Для инвариантности к средней интенсивности изображений это изображение нормируется по параметру *value* цветового пространства HSV способом, описанным в [45]. Далее это изображение переводится в изображение в градациях серого, и для него строится карта размытия способом, описанным в разделе 2.2. Детекция размытия осуществляется с помощью скользящего окна размером  $64 \times 64$  пиксела с шагом в 32 пиксела как по вертикальной, так и по горизонтальной оси. Тем самым задача детекции размытия переходит в задачу классификации патчей на два класса — резкие и размытые. Патч считается размытым при одновременном выполнении трех условий.

1. Патч принадлежит темной зоне на карте размытия. Если же среднее значение патча (обозначим за  $V$ ) на карте размытия  $D$  превышает 80, то патч считается четким (карта размытия рассматривается в градациях серого).

2. Патч не принадлежит фону. Патчи, средняя интенсивность которых превышает 170, классифицируются как фон.

3. Для всех остальных патчей анализируется пара значений  $(V, S_I)$ . Патчи из обучающей выборки были сгруппированы по значению  $V$ , для каждой из групп путем максимизации метрики  $F_1$  было определено пороговое значение  $S_I(V)$ , ниже которого патч классифицируется как размытый. Полученный график  $S_I(V)$  приведен на рис. 4.

Таким образом, для каждого изображения все его патчи делятся на резкие и размытые.

В пункте 2 был приведен порог интенсивности фоновых патчей равный 170, он был получен следующим образом: на базе набора данных PATH-DT-MSU<sup>2</sup> WSS2 был создан набор фоновых патчей размера  $64 \times 64$  с предварительной нормализацией параметра *value* в цветовом пространстве HSV [45] и конвертацией патчей в изображения в градациях серого. Для каждого

<sup>2</sup> <https://imaging.cs.msu.ru/en/research/histology/path-dt-msu>




Рис. 4. График пороговых значений  $S_I(V)$ .




Рис. 5. Общий алгоритм работы классического метода.

такого патча считалась средняя интенсивность, а затем для массива полученных значений был высчитан 0.1 квантиль, оказавшийся равным 170. Тем самым патчи, интенсивность которых была больше 170, исключались из рассмотрения.

Общая схема работы предложенного метода приведена на рис. 5.

## 5. МЕТОД НА ОСНОВЕ НЕЙРОННОГО ОПЕРАТОРА ФУРЬЕ

Fourier Neural Operator (FNO) – это метод, основанный на данных, для решения задач, описываемых классическими моделями, в том числе уравнениями в частных производных, способный сопоставлять параметры классических моделей с его решением. Его ключевыми особенностями по сравнению с классическими методами решения являются быстрое действие и инвариантность к дискретизации сетки. В данной работе рассматривается применение этого метода к задаче аппроксимации классического метода обнаружения размытых регионов на гистологических изображениях.

### 5.1. FNO

Архитектура сети FNO представлена на рис. 6. Схема преобразований входного изображения, используемая в данной работе:

1. Входное изображение подается в блок  $P$ , в котором с помощью линейных локальных опе-

раторов число каналов входа приводится к числу каналов внутреннего представления сети *hidden\_channels* = 32.

2. Далее выход блока  $P$  подается на вход несколькими слоям Фурье. Внутри этих слоев размерность входов и выходов сохраняется.

3. Выход пункта 2 подается в блок  $Q$ , в котором также с помощью линейных локальных операторов число каналов приводится к числу каналов выходного представления *out\_channels* = 3.

Внутри Фурье слоя:

1. С помощью быстрого преобразования Фурье ( $F$ ) для входа вычисляются коэффициенты Фурье, а также параллельно к входу применяется локальное линейное преобразование  $W$ .

2. Производится линейное преобразование  $R$  над низкочастотными коэффициентами Фурье и исключение из рассмотрения части высокочастотных коэффициентов.

3. Обратное преобразование Фурье.

4. Поэлементное суммирование двух преобразованных входов.

5. Применение нелинейной функции активации к выходу из слоя.

В блоке  $P$  находится два сверточных слоя с ядрами размера  $1 \times 1$ . В Фурье-слоях в качестве линейного преобразования над низкочастотными коэффициентами Фурье  $R$  используется преобразование из [46], а в качестве линейного локального преобразования  $W$  – свертка с ядром




Рис. 6. Архитектура нейронного оператора Фурье.

размера  $1 \times 1$ . Нелинейной функцией активации на выходе из Фурье-слоя является сигмоида. Всего в архитектуре данной работы восемь Фурье-слоев. В блоке  $Q$  также находятся два сверточных слоя с ядрами размерами  $1 \times 1$ .

5.2. *Общий алгоритм и данные нейросетевого метода*

Для обучения нейронной сети было использовано  $\approx 4.300.000$  патчей размерами  $64 \times 64$ . Из них  $\approx 4.000.000$  резких и  $\approx 300.000$  размытых.

Среди четких патчей:

- $\approx 3.600.000$  получены из набора данных PATH-DT-MSU WSS2 классическим методом из раздела 4;

- $\approx 400.000$  получены из тренировочной выборки набора данных FocusPath. Патчи были выбраны из изображений с уровнем размытия  $[-2, 2]$ .

Среди размытых патчей:

- $\approx 10.000$  получены из набора данных PATH-DT-MSU WSS2 классическим методом из раздела 4;

- $\approx 180.000$  получены путем применения синтетического размытия к четким патчам из набора данных PATH-DT-MSU WSS2;

- $\approx 110.000$  получены из тренировочной выборки набора данных FocusPath. Патчи были выбраны из изображений с уровнем размытия либо  $\geq 3$ , либо  $\leq 3$ .

В качестве классификатора используется нейронная сеть на базе архитектуры FNO с добавлением к ней classification head, включающую в себя average pooling слой и два полносвязных слоя с функцией активации GeLU между ними.

6. ТЕСТИРОВАНИЕ НЕЙРОСЕТЕВОГО МЕТОДА

Тестирование метода проводилось на двух тестовых выборках из наборов данных PATH-DT-MSU WSS1 и FocusPath. Выборка из WSS1 содержит 100 изображений размерами  $\approx 1500 \times 1500$ , к которым было применено синтетическое Гауссовское размытие. Выборка из FocusPath содержит 192 размеченных изображения размерами  $1024 \times 1024$ .

В табл. 1 и 2 продемонстрировано сравнение классического и предложенного нейросетевого метода на этих двух тестовых выборках. Для определения порогов классического метода использовался набор данных PATH-DT-MSU WSS2, изображения и размытия которого похожи на присутствующие в наборе WSS1. Соответственно

Таблица 1. Значения метрик методов на наборе данных WSS1

| Метод        | Precision    | Recall       | Accuracy     | F1           |
|--------------|--------------|--------------|--------------|--------------|
| Нейросетевой | 0.811        | <b>0.909</b> | 0.965        | 0.857        |
| Классический | <b>0.899</b> | 0.897        | <b>0.979</b> | <b>0.897</b> |

Таблица 2. Значения метрик методов на наборе данных FocusPath

| Метод        | Precision    | Recall       | Accuracy     | F1           |
|--------------|--------------|--------------|--------------|--------------|
| Нейросетевой | <b>0.863</b> | <b>0.884</b> | <b>0.876</b> | <b>0.873</b> |
| Классический | 0.280        | 0.018        | 0.297        | 0.033        |




Рис. 7. Визуализация детекций размытия.

нейросетевой метод, обученный, в том числе, на наборе данных, собранных классическим методом из WSS2, показывает на WSS1 немного более низкие результаты по сравнению с классическим методом. Однако классический метод [37] не способен строить карты размытия для целиком размытых изображений, отмечая все области карты размытия для таких изображений как четкие. Набор данных FocusPath состоит из целиком размытых и целиком четких изображений. В то же время нейросетевой метод лишен такого недостатка и демонстрирует удовлетворительные результаты на тестовой выборке из FocusPath. На рис. 7 зеленым отмечены результаты детекции реального размытия на изображении из набора данных WSS1.

7. ЗАКЛЮЧЕНИЕ

Предложен нейросетевой метод обнаружения размытых фрагментов на гистологических изображениях. Алгоритм FNO был обучен на результатах детектирования размытых областей классическим алгоритмом и дополнительных данных. Он продемонстрировал близкие по качеству работы результаты на изображениях набора PATH-DT-MSU, на части которого обучался

классический алгоритм. Однако, метод FNO позволил достаточно хорошо детектировать размытие и для набора FocusPath.

## 8. БЛАГОДАРНОСТИ

Исследования выполнены при финансовой поддержке Российского научного фонда в рамках научного проекта № 22-41-02002.

## СПИСОК ЛИТЕРАТУРЫ

1. *Khvostikov A., Krylov A., Mikhailov I., Malkov P.* Visualization and Analysis of Whole Slide Histological Images // *Lecture Notes in Computer Science*. 2023. V. 13644. P. 403–413.
2. *Hosseini M., Zhang Y., Plataniotis K.* Encoding visual sensitivity by maxpool convolution filters for image sharpness assessment // *IEEE Transactions on Image Processing*. 2019. V. 28. P. 4510–4525.
3. *Taqi S.A., Sami S.A., Sami L.B., Zaki S.A.* A review of artifacts in histopathology // *Journal of oral and maxillofacial pathology: JOMFP*. 2018. V. 22. P. 279–287.
4. *Priego-Torres B.M., Sanchez-Morillo D., Fernandez-Granero M.A., Garcia-Rojo M.* Automatic segmentation of whole-slide H&E stained breast histopathology images using a deep convolutional neural network architecture // *Expert Systems With Applications*. 2020. V. 151. P. 113387.
5. *Kanwal N., Perez-Bueno F., Schmidt A., Engan K., Molina R.* The devil is in the details: Whole slide image acquisition and processing for artifacts detection, color variation, and data augmentation: A review // *IEEE Access*. 2022. V. 10. P. 58821.
6. *Janowczyk A. et al.* HistoQC: an open-source quality control tool for digital pathology slides // *JCO clinic. cancer informatics*. 2019. V. 3. P. 1–7.
7. *Albuquerque T., Moreira A., Cardoso J.* Deep ordinal focus assessment for whole slide images // *Proceedings of the IEEE/CVF ICCV*. 2021. P. 657–663.
8. *Senaras C., Niazi M., Lozanski G., Gurcan M.* Deep-Focus: detection of out-of-focus regions in whole slide digital images using deep learning // *PloS one*. 2018. V. 13. P. e0205387.
9. *Kohlberger T., Liu Y., Moran M. et al.* Whole-slide image focus quality: Automatic assessment and impact on ai cancer detection // *Journal of pathology informatics*. 2019. V. 10. P. 39.
10. *Wang Z., Hosseini M., Miles A., Plataniotis K., Wang Z.* Focuslitenn: High efficiency focus quality assessment for digital pathology. MICCAI. Springer International Publishing, 2020. P. 403–413.
11. *Kanwal N. et al.* Are you sure it's an artifact? Artifact detection and uncertainty quantification in histological images // *Computerized Medical Imaging and Graphics*. 2024. V. 112. P. 102321.
12. *Faroughi S., Pawar N., Fernandes C. et al.* Physics-guided, physics-informed, and physics-encoded neural networks in scientific computing // *arXiv preprint. arXiv:2211.07377*, 2022.
13. *Li Q., Liu X., Han K., Guo C., Jiang J., Ji X., Wu X.* Learning to autofocus in whole slide imaging via physics-guided deep cascade networks // *Optics Express*. 2022. V. 30. P. 14319–14340.
14. *Alireza Golestaneh S., Karam L.* Spatially-varying blur detection based on multiscale fused and sorted transform coefficients of gradient magnitudes // *Proceedings of ICPR*. 2017. P. 5800–5809.
15. *Kumar J., Chen F., Doermann D.* Sharpness estimation for document and scene images // *Proceedings of ICPR*. 2012. P. 3292–3295.
16. *Langelaar G.C., Setyawan I., Lagendijk R.L.* Watermarking digital image and video data. A state-of-the-art overview // *IEEE Signal processing magazine*. 2000. V. 17. No. 5. P. 20–46.
17. *Shi J., Xu L., Jia J.* Discriminative blur detection features // *Proceedings of ICPR*. 2014. P. 2965–2972.
18. *Yan Q., Xu L., Shi J., Jia J.* Hierarchical saliency detection // *Proceedings of ICPR*. 2013. P. 1155–1162.
19. *Gastal E., Oliveira M.* Domain transform for edge-aware image and video processing // *ACM SIGGRAPH*. 2011. P. 1–12.
20. *Ferzli R., Karam L.J.* A no-reference objective image sharpness metric based on the notion of just noticeable blur (JNB) // *IEEE transactions on image processing*. 2009. V. 18. No. 4. P. 717–728.
21. *Назаренко Г., Насонов А., Крылов А.* Метод поиска областей размытия на гистологических изображениях. *Proceedings of the 33rd International Conference on Computer Graphics and Vision*. М.: ИПМ им. М.В. Келдыша РАН, 2023. С. 598–608. <https://doi.org/10.20948/graphicon-2023-620-632>
22. *Yuki Mochizuki* Normalize image brightness. <https://cvtech.cc/std/>
23. *Li Z., Kovachki N., Azizadenesheli K., Liu B., Bhat-tacharya K., Stuart A., Anandkumar A.* Fourier neural operator for parametric partial differential equations // *arXiv preprint. arXiv:2010.08895*, 2020.

# NEURAL NETWORK METHOD FOR DETECTING BLUR IN HISTOLOGICAL IMAGES

© 2024 G. S. Nazarenko<sup>a</sup>, A. S. Krylov<sup>a</sup>,

<sup>a</sup>Lomonosov Moscow State University, GSP-1, Moscow, 119991 Russia

In this paper we consider the problem of detecting blurred regions in high-resolution full-slide histologic images. The proposed method is based on the use of a Fourier neural operator trained on the results of two simultaneously used approaches: blur detection using multiscale analysis of the discrete cosine transform coefficients and estimation of the degree of sharpness of objects edges in the image. The efficiency of the algorithm is confirmed on images from the datasets PATH-DT-MSU [1] and FocusPath [2].

**Keywords:** histology, deep learning, blur region, Fourier neural operator

## REFERENCES

1. Khvostikov A., Krylov A., Mikhailov I., Malkov P. Visualization and Analysis of Whole Slide Histological Images // Lecture Notes in Computer Science. 2023. V. 13644. P. 403–413.
2. Hosseini M., Zhang Y., Plataniotis K. Encoding visual sensitivity by maxpool convolution filters for image sharpness assessment // IEEE Transactions on Image Processing. 2019. V. 28. P. 4510–4525.
3. Taqi S.A., Sami S.A., Sami L.B., Zaki S.A. A review of artifacts in histopathology // Journal of oral and maxillofacial pathology: JOMFP. 2018. V. 22. P. 279–287.
4. Priego-Torres B.M., Sanchez-Morillo D., Fernandez-Granero M.A., Garcia-Rojo M. Automatic segmentation of whole-slide H&E stained breast histopathology images using a deep convolutional neural network architecture // Expert Systems With Applications. 2020. V. 151. P. 113387.
5. Kanwal N., Perez-Bueno F., Schmidt A., Engan K., Molina R. The devil is in the details: Whole slide image acquisition and processing for artifacts detection, color variation, and data augmentation: A review // IEEE Access. 2022. V. 10. P. 58821.
6. Janowczyk A. et al. HistoQC: an open-source quality control tool for digital pathology slides // JCO clinic. cancer informatics. 2019. V. 3. P. 1–7.
7. Albuquerque T., Moreira A., Cardoso J. Deep ordinal focus assessment for whole slide images // Proceedings of the IEEE/CVF ICCV. 2021. P. 657–663.
8. Senaras C., Niazi M., Lozanski G., Gurcan M. Deep-Focus: detection of out-of-focus regions in whole slide digital images using deep learning // PloS one. 2018. V. 13. P. e0205387.
9. Kohlberger T., Liu Y., Moran M. et al. Whole-slide image focus quality: Automatic assessment and impact on ai cancer detection // Journal of pathology informatics. 2019. V. 10. P. 39.
10. Wang Z., Hosseini M., Miles A., Plataniotis K., Wang Z. Focuslitenn: High efficiency focus quality assessment for digital pathology. MICCAI. Springer International Publishing, 2020. P. 403–413.
11. Kanwal N. et al. Are you sure it's an artifact? Artifact detection and uncertainty quantification in histological images // Computerized Medical Imaging and Graphics. 2024. V. 112. P. 102321.
12. Faroughi S., Pawar N., Fernandes C. et al. Physics-guided, physics-informed, and physics-encoded neural networks in scientific computing // arXiv preprint. arXiv:2211.07377, 2022.
13. Li Q., Liu X., Han K., Guo C., Jiang J., Ji X., Wu X. Learning to autofocus in whole slide imaging via physics-guided deep cascade networks // Optics Express. 2022. V. 30. P. 14319–14340.
14. Alireza Golestaneh S., Karam L. Spatially-varying blur detection based on multiscale fused and sorted transform coefficients of gradient magnitudes // Proceedings of ICPR. 2017. P. 5800–5809.
15. Kumar J., Chen F., Doermann D. Sharpness estimation for document and scene images // Proceedings of ICPR. 2012. P. 3292–3295.
16. Langelaar G.C., Setyawan I., Lagendijk R.L. Watermarking digital image and video data. A state-of-the-art overview // IEEE Signal processing magazine. 2000. V. 17. No. 5. P. 20–46.
17. Shi J., Xu L., Jia J. Discriminative blur detection features // Proceedings of ICPR. 2014. P. 2965–2972.
18. Yan Q., Xu L., Shi J., Jia J. Hierarchical saliency detection // Proceedings of ICPR. 2013. P. 1155–1162.
19. Gastal E., Oliveira M. Domain transform for edge-aware image and video processing // ACM SIGGRAPH. 2011. P. 1–12.
20. Ferzli R., Karam L.J. A no-reference objective image sharpness metric based on the notion of just noticeable blur (JNB) // IEEE transactions on image processing. 2009. V. 18. No. 4. P. 717–728.
21. Nazarenko G., Nasonov A., Krylov A. A procedure for finding blur areas in histological images, Proc. // 33rd Int. Conf. on Computer Graphics and Vision. M.: Keldysh Institute of Applied Mathematics, RAS, 2023.
22. Yuki Mochizuki Normalize image brightness. <https://cvtech.cc/std/>
23. Li Z., Kovachki N., Aizzadenesheli K., Liu B., Bhattacharya K., Stuart A., Anandkumar A. Fourier neural operator for parametric partial differential equations // arXiv preprint. arXiv:2010.08895, 2020.