



# GLCM, kNN и Meanshift в задаче детектирования нейронов по изображениям срезов мозга, окрашенных по Нисслию







С. А. Носова, В.Е. Турлапов  
*svetlana.nosova@itmm.unn.ru | vadim.turlapov@itmm.unn.ru*  
Лаборатория Компьютерной Графики ННГУ  
*<http://www.graph.unn.ru>*

**Интеллектуализация обработки информации – 2018**  
12-я Международная конференция  
8-13 октября 2018 г., г. Гаэта, Италия

## Срезы коры мозга, окрашенные по Ниссляу


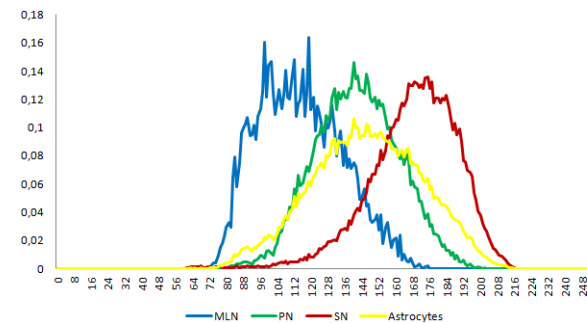
- Нейроны различны по форме.
- Размеры нейронов на одном изображении могут различаться более, чем в 2 раза.
- Изображения тел нейронов часто перекрываются
- Изображения тел нейронов могут иметь низкую контрастность с фоном.
- Изображения нейронов одного типа могут иметь значительные различия в гистограмме.
- Изображения нейронов могут иметь “пустоты” внутри своих тел.



# Объектный подход 1

Характеристики (дескрипторы) формы клеток в зависимости от слоя (Астр. – астроциты, ПН – пирамидальные нейроны, ЗН – звездчатые нейроны; НМС – нейроны молекулярного слоя)

Слой	Тип клетки	Площадь	Периметр	Протяженность	Главная диагональ	Побочная диагональ	Ориентация	Соотношение диагоналей	Компактность	Заполненность	Выпуклость	Эквивалентный диаметр
I	Астр.	139,00	55,80	0,70	17,60	11,29	97,01	1,58	0,58	0,91	0,86	13,29
	НМС	419,25	88,58	0,67	32,18	19,52	90,22	1,65	0,66	0,92	0,95	22,96
	ЗН											
II-III	Астр.	278,30	65,60	0,71	25,41	16,09	113,06	1,68	0,74	0,94	0,96	18,50
	ПН	781,02	118,60	0,72	43,18	25,37	81,54	1,74	0,70	0,94	0,95	31,38
	ЗН	1171,25	134,18	0,77	42,55	35,55	115,94	1,20	0,81	0,96	0,94	38,48
IV	Астр.	369,92	79,51	0,72	29,60	17,63	98,15	1,72	0,75	0,95	0,96	21,63
	ПН											
	ЗН	793,38	111,30	0,75	38,29	26,79	85,39	1,45	0,78	0,96	0,95	31,33
V	Астр.	340,56	72,74	0,73	26,65	17,59	102,02	1,53	0,76	0,95	0,96	20,78
	ПН	1456,23	165,32	0,68	56,61	37,75	89,80	1,55	0,66	0,92	0,94	42,44
	ЗН	1375,83	146,14	0,76	48,89	36,39	85,55	1,38	0,79	0,97	0,95	41,49
VI	Астр.	322,85	70,33	0,71	25,63	16,97	89,75	1,55	0,75	0,95	0,96	19,61
	ПН											
	ЗН	1786,98	169,24	0,75	55,31	42,58	93,00	1,31	0,78	0,96	0,94	47,24



# Объектный подход 2









Figure 5. Detection result examples

- ❑ Цель: разработка GPU-ориентированных методов детектирования.
- ❑ В этих условиях пиксельные признаки являются наиболее приоритетными.
- ❑ В наших алгоритмах детектирования определяющую роль играют текстурные признаки, построенные на основе окрестности пикселя.




- ❑ Используемые алгоритмы предобработки:
  - ❑ Различные алгоритмы конвертации в оттенки серого.
  - ❑ Выравнивание гистограммы.
  - ❑ Квантование гистограммы.
- ❑ Используемые текстурные признаки:
  - ❑ гистограммы;
  - ❑ матриц взаимной встречаемости (GLCM).
- ❑ Используемые классификаторы:
  - ❑ kNN (Евклидова дистанция);
  - ❑ Normal Bayes Classifier.
- ❑ Алгоритм кластеризации:
  - ❑ Сдвиг среднего (MeanShift).







Тренировочные данные для этапа  
классификации пикселей



Тестовые данные






- Преобразование в оттенки серого ((R,G,B)->I)
  - $Y_{luminance} = 0.3 * B + 0.59 * G + 0.11 * R$
  - $Y_R = R$
  - $Y_B = B$
  - $Y_{MAX} = \max\{R,G,B\}$
- Эквиализация (выравнивание) гистограммы
- Квантование гистограммы



$$H(i) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \begin{cases} 1, & \text{if } G(x, y) = i; \\ 0, & \text{if } G(x, y) \neq i; \end{cases}$$

$$H_{eq}(i) = \sum_{j=0}^{i-1} H(j)$$

$$G_{eq}(x, y) = H_{eq}(I(x, y)) * 255$$






- Построение гистограммы  $p(I)$ .


$$mean = \sum_{i=0}^{255} i * p_i(I); \quad m2 = \sum_{i=0}^{255} (i - mean)^2 p_i(I);$$

$$m3 = \sum_{i=0}^{255} (i - mean)^3 p_i(I); \quad m4 = \sum_{i=0}^{255} (i - mean)^4 p_i(I);$$

$$stddev = \sqrt{m2}; \quad skewness = \frac{m3}{stddev^3}; \quad kurtosis = \frac{m4}{m2^2}$$

- $\langle stddev, skewness, kurtosis \rangle$  - текстурная характеристика.





Предобработка



Вычисление  
текстурных  
характеристик  
пикселей



Классификация  
центральных  
пикселей  
нейронов



Кластеризация  
центральных  
пикселей  
нейронов

- Идея: построить матрицу взаимной встречаемости пикселей со значениями  $G_1$  и  $G_2$ , находящихся на расстоянии  $d$  в направлении  $\theta$ .


$$P_{\theta,d}(G_1, G_2) = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} \begin{cases} 1, & \text{if } G_{\text{qua}}(x, y) = G_1 \text{ and } G_{\text{qua}}(x + \theta * d, y + \theta * d) = G_2; \\ 0, & \text{otherwise.} \end{cases}$$

$$N_P = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} P_{\theta,d}(G_1, G_2)$$

$$P_{\theta,d}(G_1, G_2) = \frac{P_{\theta,d}(G_1, G_2)}{N_P}$$

- Размер матрицы  $G_{MAX} * G_{MAX}$ , где  $G_{MAX}$  – количество бинов в гистограмме
  - В нашем случае  $G_{MAX} = 8$
- Используются следующие значения:  
 $d = 1$  и  $\theta = 0^0, 45^0, 90^0, 135^0$  (для каждого региона строится 4 матрицы)
- По матрицам строится текстурная характеристика

$d=1$  - оптимальный из рассмотренных.



# Текстурные дескрипторы. GLCM

angular second moment (homogeneity),

$$ASM_{\theta,d} = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} P_{\theta,d}(G_1, G_2)^2$$

contrast,

$$CONT_{\theta,d} = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} P_{\theta,d}(G_1, G_2) * (G_1 - G_2)^2$$

correlation,

$$COR_{\theta,d} = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} \frac{G_1 * G_2 * P_{\theta,d}(G_1, G_2) - \mu_x * \mu_y}{\sigma_x * \sigma_y}$$

$$\mu_x = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} G_1 * P_{\theta,d}$$

$$\mu_y = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} G_2 * P_{\theta,d}$$

$$\sigma_x = \sum_{G_1=0}^{G_{MAX}-1} (G_1 - \mu_x)^2 \sum_{G_2=0}^{G_{MAX}-1} P_{\theta,d}$$

$$\sigma_y = \sum_{G_2=0}^{G_{MAX}-1} (G_2 - \mu_y)^2 \sum_{G_1=0}^{G_{MAX}-1} P_{\theta,d}$$

inverse difference moment (local homogeneity)

$$IDM_{\theta,d} = \sum_{G_1=0}^{G_{MAX}-1} \sum_{G_2=0}^{G_{MAX}-1} \frac{1}{1 + (G_1 - G_2)^2} * P_{\theta,d}(G_1, G_2).$$

$$ST_{\theta,d} = [ASM_{\theta,d}, CONT_{\theta,d}, COR_{\theta,d}, IDM_{\theta,d}]$$

$$ST_d = \frac{1}{4} \sum_{\theta} ST_{\theta,d}$$

Предобработка



Вычисление  
текстурных  
характеристик  
пикселей

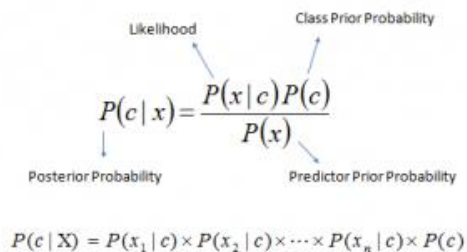


Классификация  
центральных  
пикселей  
нейронов



Кластеризация  
центральных  
пикселей  
нейронов

- $k$  ближайших соседей (kNN)
  - для каждого используемого набора признаков в качестве класса выбирается тот класс, за который «проголосовало» наибольшее количество тестовых признаков из  $k$  ближайших соседей.
  - В качестве метрики расстояния использована Евклидова метрика.
- Нормальный байесовский классификатор (NBC)
  - Наивный байесовский классификатор
  - Предполагаем, что значения признаков имеют нормальное распределение.
  - Выбрать класс с наибольшей вероятностью попадания в него.


$$P(c|x) = \frac{P(x|c)P(c)}{P(x)}$$

$P(c|X) = P(x_1|c) \times P(x_2|c) \times \dots \times P(x_n|c) \times P(c)$

$P(c/x)$  – апостериорная вероятность данного класса  $c$  (т.е. данного значения целевой переменной) при данном значении признака  $x$ .

$P(c)$  – априорная вероятность данного класса.

$P(x/c)$  – правдоподобие, т.е. вероятность данного значения признака при данном классе.

$P(x)$  – априорная вероятность данного значения признака.

Предобработка



Вычисление  
текстурных  
характеристик  
пикселей



Классификация  
центральных  
пикселей  
нейронов



Кластеризация  
центральных  
пикселей  
нейронов


- Положить, что  $x$  – центр кластера.
- Вычислить положение  $m(x)$  средней плотности пикселей, детектированных как нейрон, из окрестности  $R$  текущего пикселя по формуле ниже.

$$K(x) = \begin{cases} 1, & \text{if } \|x\| \leq R \\ 0, & \text{if } \|x\| > R \end{cases}; \quad m(x) = \frac{\sum_{s \in S} K(s-x)s}{\sum_{s \in S} K(s-x)}$$

где  $s$  – пиксель из окрестности  $x$ , принадлежащий нейрону;  $S$  – множество пикселей, детектированных как нейроны, из окрестности радиуса  $R$  пикселя  $x$ .

- Вычислить сдвиг среднего  $m(x) - x$ . Если  $|m(x) - x| > \epsilon$ , переместить  $x$  в точку  $m(x)$  и повторить процедуру, начиная с п.2. В противном случае

перейти к следующему пикселю



$$Recall = \frac{TP}{TP + FN}$$


$$Precision = \frac{TP}{TP + FP}$$

$$F1 = \frac{2 * Recall * Precision}{Recall + Precision}$$


1. Положить  $TP = 0$ ,  $FP = 0$ ,  $FN = 0$ .
2. Для каждого детектированного центра  $c_i$ :
  1. Найти ближайший (размеченный специалистом центр нейрона)  $m_j$
  2. Если  $|c_i - m_j| < R_{acc}$ , где  $R_{acc}$  – средний радиус нейрона; то увеличить  $TP$  на 1 и удалить  $m_j$  и  $c_i$  из рассмотрения. В противном случае, увеличить  $FP$  на 1.
3. Для каждого центра  $m_j$ , для которого не был найден  $c_i$ :
  1. Увеличить  $FN$  на 1

- Язык\компилятор: C++, MVS
- Библиотеки\технологии: OpenCV, CUDA
- Характеристики системы:
  - Intel® Core™ i7-3820 CPU @ 3.6 GHz 3.6 GHz
  - 16Gb RAM
  - 64-bit OS Windows 7
  - Nvidia GeForce GTX 680
- Тестовые данные
  - BrainMaps: An Interactive Multiresolution Brain Atlas;  
<http://brainmaps.org> [retrieved on 15.05.2018]






Hist



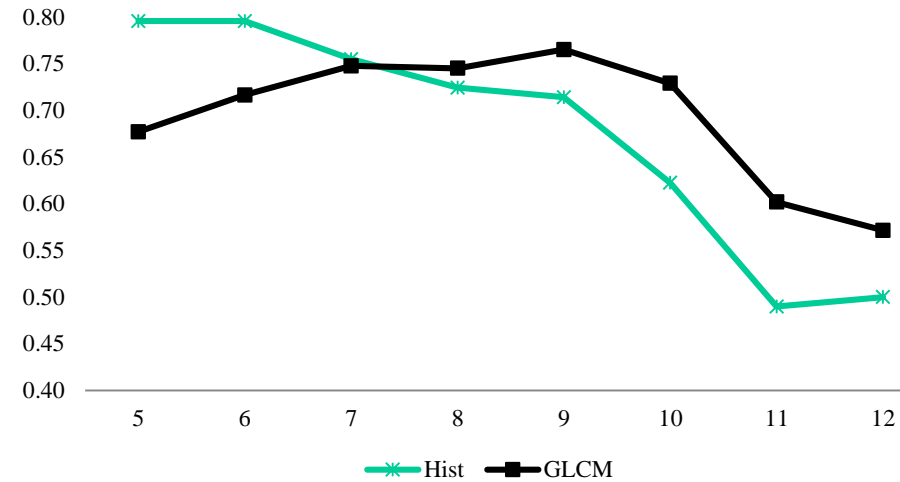
GLCM

# Результаты


### F1 score



### Precision

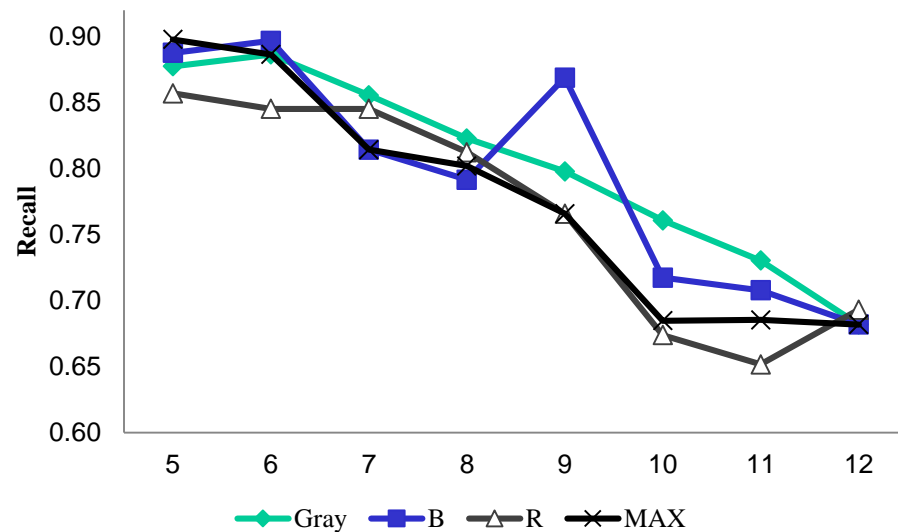
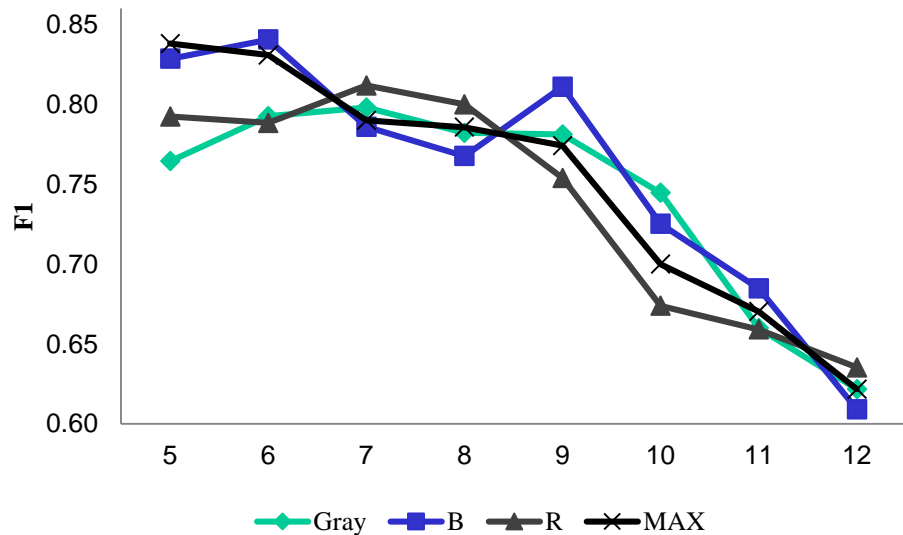


### Recall




Лучший результат достигается при использовании GLCM.

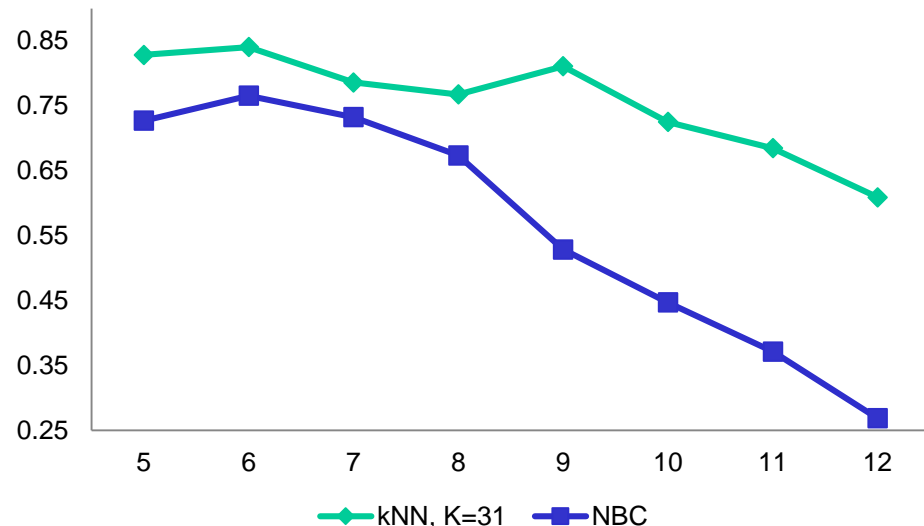

# Результаты



Лучший результат достигается при использовании только синей (B, blue) компоненты цвета.ы



# Результаты

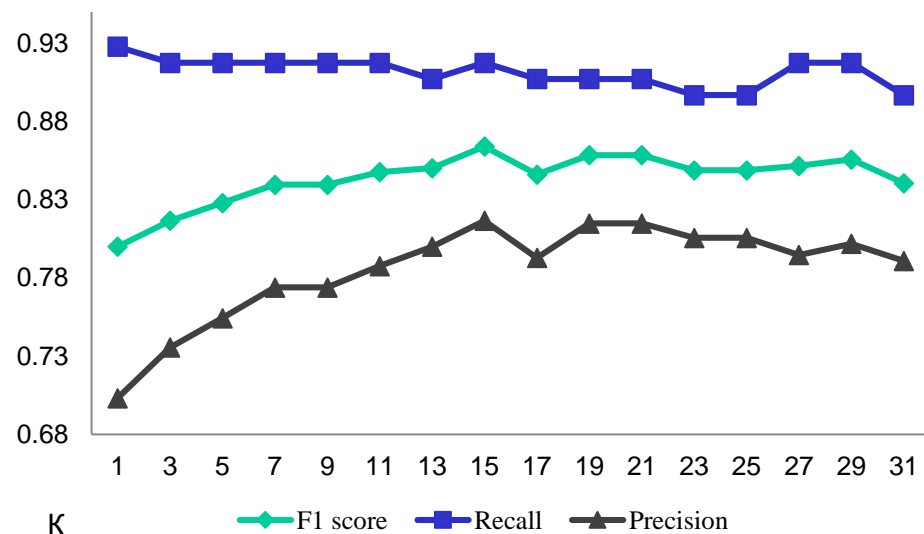


❑ Лучший результат достигается при использовании kNN.

❑ Использование  $k > 15$  не дает прирост качества детектирования.

❑ Лучшие результаты достигаются при  $R=6$ , что соответствует радиусу нейрона.

❑ Выбор квантования (2, 4 или 8 бинов) гистограммы при использовании GLCM дает схожие результаты ( $F1 = 0, 83..0, 85$ ).



- ❑ Предложен алгоритм для детектирования центров нейронов:
  - ❑ Предобработка ( перевод в оттенки серого, выравнивание гистограммы, квантование гистограммы);
  - ❑ Вычисление текстурных признаков (GLCM);
  - ❑ классификация пикселей при помощи алгоритма kNN (детектирование центральных пикселей нейрона);
  - ❑ mean shift для кластеризации полученных пикселей (детектирование нейрона).
- ❑ В работе  $Recall(A) = 86 \pm 5\%$ . Предложенный метод показывает аналогичный (иногда-лучший) результат.
  - ❑ Inglis A., Cruz L., Roe D. L., Stanley H.E., Rosene D. L., and Urbanc B. Automated identification of neurons and their locations. // Journal of Microscopy., 2008. Vol. Jun;230(Pt 3):339-52.167 doi: <http://dx.doi.org/10.1111/j.1365-2818.2008.01992.x>
- ❑ В работе показано, что  $F1=0,8-0,9$  – хорошее качество детектирования для отдельных наборов данных (для многих - хуже).
  - ❑ Yao Xue, Nilanjan Ray. Cell Detection in Microscopy Images with Deep Convolutional Neural Network and Compressed Sensing. arXiv:1708.03307v3 [cs.CV] 21 Feb 2018



УНИВЕРСИТЕТ  
ЛОБАЧЕВСКОГО



# Спасибо за внимание!

С. А. Носова, В.Е. Турлапов  
*svetlana.nosova@itmm.unn.ru | vadim.turlapov@itmm.unn.ru*  
Лаборатория Компьютерной Графики ННГУ  
*<http://www.graph.unn.ru>*

**Интеллектуализация обработки информации – 2018**  
12-я Международная конференция  
8-13 октября 2018 г., г. Гаэта, Италия