

Санкт-Петербургский Государственный Университет
Математическое обеспечение и администрирование информационных
систем

Системное программирование

Нагаев Артур Рафкатович

Классификация снимков МРТ головного мозга

Курсовая работа

Научный руководитель:
ст. преп. С. Ю. Сартасов

Санкт-Петербург
2018

SAINT-PETERSBURG STATE UNIVERSITY
Software and Administration of Information Systems

Department of Software Engineering

Arthur Nagaev

Brain MRI images classification

Course Work

Scientific supervisor:
Assistant professor Stanislav Sartasov

Saint-Petersburg
2018

Оглавление

Введение	4
1. Постановка задачи	5
2. Обзор литературы	6
3. Данные	10
4. Реализация	12
4.1. Данные	12
4.2. Предварительная обработка	12
4.3. Выделение признаков	13
4.4. Классификация	15
4.5. Используемые технологии	15
5. Апробация	16
6. Заключение	18
Список литературы	19

Введение

В настоящее время к технологиям машинного обучения проявляется большой интерес в связи с многообещающими результатами в различных областях, таких как распознавание речи, распознавание рукописного текста, классификация изображений, определение и сегментация различных объектов на изображениях и др. В частности, к задачам машинного обучения сводятся многие задачи медицины, например, обнаружение опухолей. Последовательное развитие клеток внутричерепных новообразований приводит к серьезным нарушениям работы головного мозга или смерти больного. Поэтому раннее обнаружение опухоли и обеспечение подходящего лечения составляют основу, необходимую для выздоровления пациента. Магнитно-резонансная томография (МРТ) — основной способ определения новообразований головного мозга. С помощью МРТ можно создавать изображения тканей мозга, по которым рентгенологи могут проводить диагностику заболевания. Здесь можно выделить две основные проблемы: скорость работы и точность определения диагноза. Рентгенологи не могут быстро просматривать снимки МРТ, потому что это может привести к ошибкам в диагностировании заболевания. Ошибки делятся на ошибки первого рода и ошибки второго рода. Ошибка первого рода говорит о том, что у здорового пациента нашли опухоль. Такие ошибки не являются опасными, так как после диагностирования проводится повторное исследование, в рамках которого можно выяснить, что пациент здоров. Действительно опасными являются ошибки второго рода, которые свидетельствуют о том, что у больного пациента не были найдены новообразования. Такие ошибки зачастую приводят к летальному исходу или серьезным осложнениям. Использование в медицине технологии автоматизированного определения новообразований в перспективе может позволить уменьшить число врачебных ошибок, а также позволит врачам переложить существенный пласт работы на систему [1].

1. Постановка задачи

Целью данной работы является создание модуля для классификации МРТ изображений. Для достижения этой цели необходимо решить следующие задачи:

- Сделать обзор способов классификации снимков МРТ головного мозга
- Реализовать модуль для классификации снимков МРТ головного мозга
- Подготовить данные для обучения модели алгоритма
- Реализовать модель и обучить её на подготовленных данных
- Провести апробацию модели

2. Обзор литературы

Задачу классификации изображений можно разделить на следующие этапы:

- Предварительная обработка
- Выделение признаков
- Классификация по признакам

Существуют различные подходы к классификации снимков МРТ. Сравним их поэтапно.

Большинство подходов работают схожим образом на этапе предварительной обработки данных. Снимки МРТ представляет собой последовательные двумерные срезы головного мозга. Предобработка зачастую сводится к фильтрации изображений. Существует множество фильтров, позволяющих избавляться от шума в изображениях (рис. 1). Самыми популярными из них среди статей являются: фильтр Гаусса, имеющий вид: $g(x, y) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{x^2+y^2}{2\sigma^2}}$ и медианный фильтр, имеющий вид: $f(x, y) = \text{med}_{(st) \in S_{xy}} \text{img}(s, t)$ Для усиления контраста изображения применяются гамма-коррекция, $\text{img}(x, y) = A \cdot (\text{img}(x, y))^\gamma$, где A, γ — числа, и выравнивание гистограммы (histogram equalization).

В таблице 1 по используемым методам сравниваются основные существующие решения в данной области.

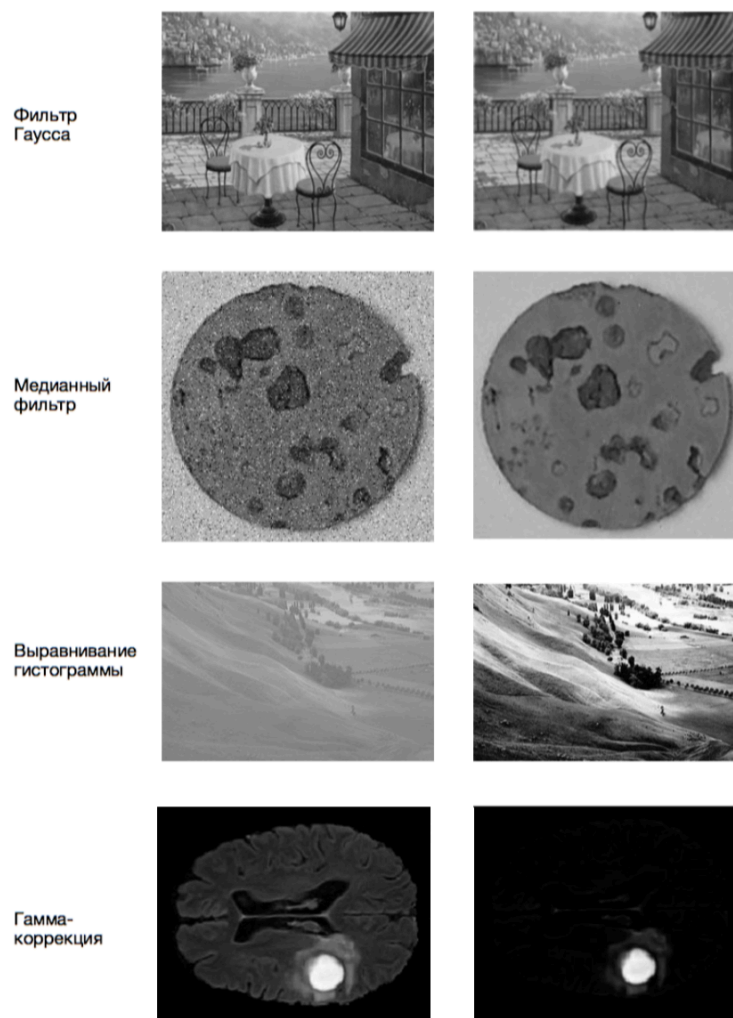


Рис. 1: Примеры применения предварительной обработки изображений

Статья	Год	Предобработка	Выделение особенностей	Классификация
SivaSankari [2]	2014	Медианный фильтр + сегментация через k-nn	GLCM	Не применялась
Amsaveni [3]	2013	Медианный фильтр	Фильтр Габо-ра + ANN для сегментации	Не применялась
Gawande [4]	2017	Сегментация водоразделом	GLCM + DWT	DNN
Chaplot [5]	2006	Не применялась	DWT	SVM
Zulpe [6]	2012	Фильтр Гаусса	GLCM	ANN

Таблица 1: Сравнение статей по используемым методам

Для выделения признаков в изученных статьях использовались:

- GLCM (grey level co-occurrence matrix)
- DWT (дискретные вейвлет преобразования)
- CNN (сверточные нейронные сети)
- Фильтр Габора

GLCM представляет собой матрицу, составленную из значений, равных числу встречающихся пространственных связей среди интенсивностей изображения. Признаками в данном случае являются статистические характеристики этой матрицы. Принцип выделения особенностей у дискретного вейвлет-преобразования и фильтра Габора схож со сверточными нейронными сетями. На изображение последовательно накладываются фильтры (свертки), преобразовывая его. Характерные значения интенсивностей преобразованного изображения в данном случае являются его признаками. Среди большого числа признаков, полученных с помощью дискретного вейвлет-преобразования можно выделить особо выделяющиеся с помощью метода главных компонент. Преобразование изображения с помощью фильтра Габора или дискретного вейвлет-преобразования можно также использовать на этапе предварительной обработки данных, например, для выделения различных контуров. Признаки, выделяемые свёрточной нейронной сетью, являются скрытыми. В слоях субдискретизации (pooling) происходит уменьшение карты признаков в пропорциональное двум число раз. Однако существенный недостаток сверточных нейронных сетей состоит в том, что для их работы требуются большие вычислительные ресурсы.

Многие исследователи составляют различные комбинации из выделенных признаков в паттерны, принимающие различные значения на частях снимка с опухолью и без неё. Части, имеющие опухоль (или не имеющие) при этом могут сильно отличаться друг от друга по структуре ткани (белое или серое вещество, костная ткань и др.) [7].

Для классификации по признакам используются следующие методы:

- SVM (машина опорных векторов)
- ANN (искусственная нейронная сеть)
- k-NN (метод k-ближайших соседей)
- CNN (сверточные нейронные сети)

Однако сложно сказать, какой метод является наиболее подходящим к данной задаче, поскольку результат очень сильно зависит от данных, на которых модели обучаются и тестируются. В таблице 2 приведено сравнение рассматриваемых статей по данным и точности классификации.

Статья	Год	Число снимков	Число здоровых снимков	Типы снимков	Ассигасу, %
SivaSankari [2]	2014	30	0	Не указано	Нет
Amsaveni [3]	2013	40	0	Не указано	89.9
Gawande [4]	2017	300	0	Глиомы, менингиомы, аденомы гипофиза	92.3
Chaplot [5]	2006	52	6	Болезнь Альцгеймера	98
Zulpe [6]	2012	80	0	Астроциомы, менингиомы, саркомы, карциномы	97.5

Таблица 2: Описание данных и результатов в статьях

3. Данные

Снимки МРТ представляют собой последовательные двумерные срезы головного мозга. Для обучения модели в связи с доступностью был выбран набор данных с соревнования по сегментации МРТ изображений BRATS-2017 [8]. Данные состоят из снимков 285 пациентов, имеющих глиобластомы (самый агрессивный подвид глиом). Каждый снимок снят в следующих режимах МРТ: T1, T2, T1ce, flair. Снимки обработаны вручную специалистами: на них присутствуют только ткани головного мозга, поэтому использовать эти снимки с доступными здоровыми снимками не представляется возможным, так как они не являются размеченными. Поэтому среди имеющихся снимков были отобраны 32 таких, на выбранном горизонтальном срезе которых ткани не были задеты опухолью. Выбирался именно тот срез, на котором средняя площадь тканей была максимальна среди всех изображений. Среди оставшихся снимков были отобраны те, выбранный срез которых задевался ядром опухоли. Таким образом, набор снимков для одного пациента (как здорового, так и больного) состоит из двумерных изображений заданного среза четырех типов МРТ. На рис. 2 представлены примеры таких изображений. На рис. 3 изображены различные горизонтальные срезы необработанного МРТ изображения типа T2 здорового пациента. Также для тестирования работы модуля использовался набор данных MNIST [9], состоящий из изображений рукописных цифр от 0 до 9, из которого были отобраны 462 изображения нулей и 538 изображений единиц.




Рис. 2: Примеры срезов МРТ изображений (справа ”здоровый” мозг)




Рис. 3: Пример снимка МРТ здорового пациента

4. Реализация

4.1. Данные

Класс MRI представляет собой снимок МРТ. Класс Data представляет собой коллекцию снимков МРТ разных типов одного пациента. DataStorage – коллекция снимков разных пациентов.




Рис. 4: UML-диаграмма модуля данных

4.2. Предварительная обработка

Для избавления от шума используется фильтр Гаусса. В качестве усилителя контраста используется гамма-коррекция. Также отбрасывается 2% старших интенсивностей, являющихся выбросами, и изображение G нормализуется следующим образом:

$$G = \frac{G - \text{mean}(G)}{\text{std}(G)}$$

Среди всех изображений одного класса вычисляется среднее значение интенсивности M , затем каждое изображение в рамках одного класса преобразовывается следующим образом:

$$G = \frac{G * M}{\text{mean}(G)}$$

Это нужно для того, чтобы учитывать, что снимки одного типа, сделанные на разных аппаратах, могут иметь различные средние значения интенсивностей. В конечном итоге каждое изображение нормируется:

$$G = \frac{k_{\max}}{\max(G)} G$$

После этого преобразования максимальное значение интенсивности в нем будет равно k_{max} . Это нужно для того, чтобы порядок матрицы GLCM, равный числу различных интенсивностей, не был большим. Класс `DataProcessing` позволяет проводить требуемую обработку списка снимков, а также возвращать список, состоящий из признаков каждого изображения. Используя этот класс можно создавать комбинации признаков, выявленных из заданных типов МРТ изображений без привязки к конкретному.




Рис. 5: UML-диаграмма модуля предварительный обработки

4.3. Выделение признаков

Для выделения признаков в связи с хорошими результатами в изученных исследованиях был выбран метод, основанный на использовании матрицы GLCM. Матрица GLCM строится следующим образом.

$$M(i, j) = \sum_{x=1}^{X_n - \delta_x} \sum_{y=1}^{Y_n - \delta_y} C_{i,j}, \quad C_{i,j} = \{G(x, y) = i \text{ and } G(x + \delta_x, y + \delta_y) = j ? 1 : 0\}$$

Каждый элемент $G(i, j)$ этой матрицы равен числу пространственных связей между интенсивностями i и j . Рассмотрим рис. 6:




Рис. 6: Пример построения GLCM матрицы

Элемент данной GLCM матрицы $M(1, 2) = 2$, заданной для пространственной связи $(\delta_x, \delta_y) = (1, 0)$ говорит о том, что на данном изображении существует ровно 2 пары интенсивностей, таких, что значение слева равно 1, а значение справа равно 2. Признаками изображения будут являться следующие величины:

$$contrast = \sum_{i,j=1}^{n-1} M(i, j) * (i - j)^2$$

$$dissimilarity = \sum_{i,j=1}^{n-1} M(i, j) * |i - j|$$

$$homogeneity = \sum_{i,j=1}^{n-1} \frac{M(i, j)}{1 + (i - j)^2}$$

$$ASM = \sum_{i,j=1}^{n-1} M(i, j)^2$$

$$energy = \sqrt{ASM}$$

$$correlation = \sum_{i,j=1}^{n-1} M(i, j) \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}},$$

$$\mu_i = \sum_{i,j=1}^{n-1} iM(i, j), \mu_j = \sum_{i,j=1}^{n-1} jM(i, j), \sigma_k = \sum_{i,k=1}^{n-1} M(i, k)(k - \mu_k)^2$$

Для каждого пациента по изображениям четырёх типов строились наборы по 6 признаков для четырех пространственных связей $((-1, 1); (0, 1); (1, 1); (1, 0))$, а также 6 признаков, каждый из которых является средним арифметическим признаков одного типа из четырёх наборов. Итого для каждого пациента строится набор из 120 признаков.

4.4. Классификация

Класс Classifier позволяет проводить бинарную классификацию с помощью искусственной нейронной сети [6], машины опорных векторов [5] или метода k-ближайших соседей [2]. В качестве модели искусственной нейронной сети была выбрана модель многослойный перцептрон (Рис. 7).




Рис. 7: Схема модели многослойный перцептрон

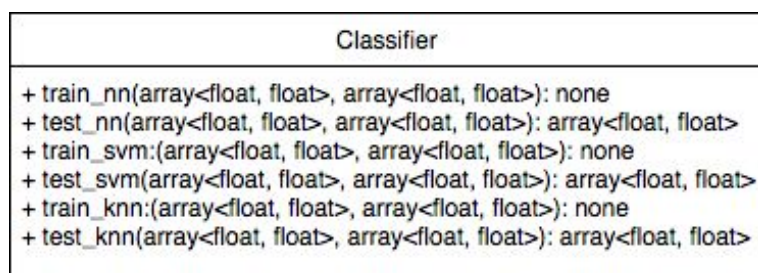


Рис. 8: UML-диаграмма модуля классификации

4.5. Используемые технологии

Для написания программы был выбран язык Python 3.6. Для чтения МРТ изображений в формате nii была использована библиотека nibabel. Визуализация снимков была реализована с помощью библиотеки matplotlib. Для предварительной обработки изображений, а также для выделения признаков с помощью матрицы GLCM использовалась библиотека scikit-image. Для классификации была выбрана реализация метода опорных векторов и метода k-ближайших соседей в библиотеке scikit-learn, а также реализация нейронной сети в библиотеке pyrenn.

5. Апробация

Наличие снимков плохого качества в основном наборе данных и разнообразие форм тканей опухолей на изображениях безусловно негативно сказываются на точности классификации. Поэтому для тестирования работы классификаторов с данными видами новообразований из основного набора BRATS-2017 были дополнительно отобраны 45 снимков, на которых есть легко отличимая на глаз опухоль, и 24 здоровых снимка. В следующих таблицах приведены результаты тестирования.

Набор данных: BRATS-2017

Размер обучающей выборки: 165 (17 здоровых)

Размер тестовой выборки: 65 (15 здоровых)

Метод	Accuracy	Precision	Recall
ANN	0.82	0.34	0.71
SVM	0.77	0.0	TP+FN=0
k-NN	0.72	0.0	0.0

Таблица 3: Сравнение результатов работы классификаторов на наборе данных BRATS-2017

Набор данных: подвыборка BRATS-2017

Размер обучающей выборки: 44 (14 здоровых)

Размер тестовой выборки: 25 (10 здоровых)

Метод	Accuracy	Precision	Recall
ANN	0.6	0.4	0.5
SVM	0.44	0.1	0.17
k-NN	0.48	0.1	0.2

Таблица 4: Сравнение результатов работы классификаторов на подвыборке BRATS-2017

Набор данных: подвыборка MNIST

Размер обучающей выборки: 800 (371 нуль)

Размер тестовой выборки: 200 (91 нуль)

Метод	Ассурасу	Precision	Recall
ANN	0.99	0.99	0.98
SVM	0.87	1.0	0.78
k-NN	0.99	1.0	0.98

Таблица 5: Сравнение результатов работы классификаторов на наборе данных MNIST

Таким образом, на имеющемся наборе снимков МРТ классификация по выбранным признакам не показала положительного результата. Это может быть связано с неоднородностью данных, а также со спецификой глиобластом.

6. Заключение

В рамках курсовой работы было выполнено следующее:

- Выполнен обзор, а также были изучены способы классификации МРТ изображений
- Подготовлены данные для обучения модели
- Проведена апробация моделей на подготовленных данных
- Был создан модуль для классификации снимков МРТ

Список литературы

- [1] Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, and Andrew Y. Ng. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *CoRR*, abs/1711.05225, 2017.
- [2] Sangeetha ShenbagaRajan SivaSankari, Sindhu. Feature extraction of brain tumor using mri. 3(3), 2014.
- [3] V. Amsaveni and N. A. Singh. Detection of brain tumor using neural network. pages 1–5, July 2013.
- [4] Vrushali Mendre Suraj S. Gawande. Brain tumor diagnosis using deep neural network (dnn). *IJIRCCE*, 5, May 2017.
- [5] Sandeep Chaplot, Lalit Patnaik, and N.R. Jagannathan. Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network. 1:86–92, 01 2006.
- [6] Nitish Zulpe and Vrushsen Pawar. Glcm textural features for brain tumor classification. *IJCSI International Journal of Computer Science Issues*, 9, May 2012.
- [7] L. O. Hall, A. M. Bensaid, L. P. Clarke, R. P. Velthuizen, M. S. Silbiger, and J. C. Bezdek. A comparison of neural network and fuzzy clustering techniques in segmenting magnetic resonance images of the brain. *IEEE Transactions on Neural Networks*, 3(5):672–682, Sep 1992.
- [8] Bjoern Menze and Andras Jakab. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Transactions on Medical Imaging*, page 33, 2014.
- [9] Yann LeCun and Corinna Cortes. MNIST handwritten digit database. 2010.