

Повышение эффективности анализа изображений МРТ головного мозга с использованием отбора признаков

В.В. Коневский¹, А.В. Благов¹, А.В. Гайдель^{1,2}, А.В. Капишников³,
А.В. Куприянов¹, Е.Н. Суровцев³, Д.Г. Асатрян^{4,5}

¹ Самарский национальный исследовательский университет имени академика С.П. Королёва,
443086, Россия, г. Самара, Московское шоссе, д. 34;

² ИСОИ РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН,
443001, Россия, г. Самара, ул. Молодогвардейская, д. 151;

³ Федеральное государственное бюджетное образовательное учреждение высшего образования
«Самарский государственный медицинский университет»

Министерства здравоохранения Российской Федерации, 443099, Россия, г. Самара, ул. Чапаевская, д. 89;

⁴ Российско-Армянский (Славянский) университет, Ереван, Армения,

⁵ Институт проблем информатики и автоматизации национальной академии наук, Ереван, Армения

Аннотация

В данной статье рассматривается возможность повышения качества анализа изображений МРТ головного мозга в различных режимах сканирования путем использования алгоритмов жадного отбора признаков. Всего было рассмотрено пять последовательностей МРТ. Формирование текстурных признаков производилось с использованием программного комплекса MaZda. С использованием алгоритма рекурсивного отбора признаков удалось повысить точность определения типа опухоли с 69 % до 100 %. С помощью комбинированного алгоритма отбора признаков удалось повысить точность определения необходимости лечения пациента с 60 % до 78 % и с 81 % до 88 % в случае использования дополнительного класса, содержащего в себе данные пациентов, у которых точный результат лечения не известен. Использование текстурных признаков в совокупности с признаком, отвечающим за тип менингиомы, позволило однозначно определить необходимость лечения пациента.

Ключевые слова: текстурный анализ, компьютерная оптика, обработка изображений, жадные алгоритмы, диагностика МРТ, менингиома.

Цитирование: Коневский, В.В. Повышение эффективности анализа изображений МРТ головного мозга с использованием отбора признаков / В.В. Коневский, А.В. Благов, А.В. Гайдель, А.В. Капишников, А.В. Куприянов, Е.Н. Суровцев, Д.Г. Асатрян // Компьютерная оптика. – 2022. – Т. 46, № 4. – С. 621-627. – DOI: 10.18287/2412-6179-CO-1040.

Citation: Konevsky VV, Blagov AV, Gaidel AV, Kapishnikov AV, Kupriyanov AV, Surovtsev EN, Asatryan DG. Improving the efficiency of brain MRI image analysis using feature selection. Computer Optics 2022; 46(4): 621-627. DOI: 10.18287/2412-6179-CO-1040.

Введение

Работа посвящена повышению качества диагностики первичных внеочередных объемных образований (ПВОО) при МРТ головного мозга и определению персонализированных критериев отбора пациентов для радиохирургического лечения путем использования методов отбора информационных признаков.

ПВОО являются наиболее распространенными внутричерепными опухолями у взрослых [1, 2] и представлены широким спектром гистологических вариантов с различной степенью злокачественности [1]. Радиологический диагноз ПВОО должен быть установлен с помощью магнитно-резонансной томографии (МРТ) [4–7].

Подход к лечению ПВОО включает три варианта: динамическое наблюдение, нейрохирургическое вмешательство и стереотаксическую лучевую терапию (SRS) [4, 5]. SRS является полностью неинвазив-

ным способом лечения и направлена на достижение контроля за ростом образования (остановку его роста) [8]. Однако в отдельных случаях после SRS наблюдается увеличение размеров опухоли, что может негативно сказываться на состоянии больного [9, 10]. Такая неопределенность лечебного эффекта SRS приводит к недостаточному ее внедрению в клиническую практику в то время, как более распространенное хирургическое вмешательство может привести к развитию осложнений и снизить качество жизни пациента [11].

В последние годы сформировалось новое направление в высокотехнологическом анализе медицинских изображений, получившее наименование «радиомика». Концепция радиомики базируется на извлечении большого массива разнообразных признаков путем углубленного компьютерного анализа изображений и применения их в системах поддержки принятия клинических решений [12, 13]. Использование количественных данных медицинских изображе-

ний в качестве биомаркеров имеет значительный клинический потенциал как на этапе планирования лечения, так и на этапе оценки его эффективности.

Таким образом, совершенствование диагностических и прогностических возможностей МРТ у пациентов с ПВОО на основе извлечения цифровых признаков с помощью современных информационных технологий является актуальной проблемой лучевой диагностики. Средства автоматизированной диагностики смогли бы ускорить и удешевить обследование пациентов.

В данной работе для формирования признаков используется программа MaZda, позволяющая получить 298 текстурных характеристик изображения. Выбор признаков выполняется с использованием жадных алгоритмов: рекурсивного отбора, прямого выбора, обратного исключения, а также комбинации прямого выбора и обратного исключения. Эти алгоритмы позволяют выбрать наиболее информативные признаки для дальнейшей классификации объектов на заданное количество классов.

Описание набора данных

Изображения магнитно-резонансной томографии головного мозга были получены при обследовании пациентов в клиниках Самарского государственного медицинского университета. Набор данных состоял из 650 цифровых изображений, на каждом из которых медицинским специалистом была вручную выделена область интереса, представляющая собой участок патологических изменений. Изображения были получены для пяти последовательностей (режимов сканирования) МРТ:

- С (T1 ВИ после в/в контрастирования): 150 изображений,
- D (DWI измерение броуновского движения молекул): 80 изображений,
- F (FLAIR): 133 изображения,
- T1 ВИ: 142 изображения,
- T2 ВИ: 145 изображений.

На рис. 1 представлен пример исходного изображения. Невооружённым глазом можно увидеть новообразование.




Рис. 1. МРТ головного мозга в аксиальной проекции, режим сканирования С с маской для новообразования

МРТ были предоставлены для 70 пациентов с описанной историей болезни. Возраст пациентов варьировался от 19 до 76 лет, средний возраст составил 56 лет. Из них 10 человек были мужчинами и 60 женщинами.

Определением предполагаемого гистологического типа ПВОО по типичной МРТ семиотике и выделением зоны интереса занимался эксперт. Были возможны следующие типы ПВОО: атипичная (злокачественная) менингиома, типичная (доброкачественная) менингиома и невринома.

После прохождения МРТ части пациентов было выполнено SRS. Набор данных содержал в себе информацию как для пациентов, подвергшихся SRS, так и для пациентов, не прошедших данное лечение, но проходивших контрольные исследования для динамического наблюдения за опухолью. Все пациенты после SRS проходили контрольное МРТ-исследование для наблюдения за результатом выполненного лечения. По результатам лечения были результаты: прогрессирующее, частичный ответ, незначительный ответ, стабилизация, а также были пациенты, для которых результаты лечения определить не удалось. Результат лечения SRS оценивался согласно критериям RANO [14].

Выбор необходимости лечения осуществлялся по следующему алгоритму. Использовались три класса: лечение требуется, лечение не требуется, недостаточно данных для принятия решения. Если без лечения наблюдается стабилизация – лечение не требуется. Если без лечения наблюдается прогрессирующее – лечение требуется. Если с лечением наблюдается стабилизация – лечение требуется. Если с лечением наблюдается прогрессирующее – лечение не требуется. Частичный или незначительный ответ считался так же, как стабилизация.

Текстурный анализ

Для количественного описания областей интереса были вычислены текстурные признаки. Текстурные признаки вычислялись с помощью программного пакета MaZda. MaZda – это программный инструмент для анализа изображений. Его эффективность была доказана участниками различных проектов, которые использовали это программное обеспечение для различных задач, где был необходим текстурный анализ, [15]. Признаки, вычисляющиеся с помощью MaZda, включают в себя:

- гистограммные характеристики (среднее, дисперсия, коэффициент асимметрии, коэффициент эксцесса и др.);
- градиентные характеристики (те же среднее, дисперсия, коэффициент асимметрии, коэффициент эксцесса и др., но для градиента изображения);
- признаки, основанные на длинах серий (второй угловой момент, контраст, корреляция и др.);
- признаки, основанные на матрице взаимной встречаемости (признаки Харалика);
- признаки, основанные на модели авторегрессии (коэффициенты в этой модели);

– признаки, основанные на вейвлет-преобразовании (энергетические характеристики изображения на разных масштабах различных вейвлет-преобразований).

Таким образом, при проведении текстурного анализа было получено 298 признаков.

Задача отбора признаков

Отбор признаков необходим для повышения результатов классификации. В общем виде проблема отбора признаков заключается в том, что требуется выбрать некоторое подмножество из имеющегося множества примитивных признаков, которое позволяет оптимизировать некоторый критерий качества признакового пространства.

Допустим, имеется множество распознаваемых объектов Ω , разбитое на L классов Ω_j

$$\Delta = \{\Omega_j\}_{j=0}^{L-1}. \quad (1)$$

Каждый объект распознавания $\omega \in \Omega$ представляет собой вектор из M вещественных чисел (признаков).

Для решения задачи классификации необходимо построить оператор $\tilde{\Phi}(x): \Omega \rightarrow [0; L-1] \cap Z$, который по вектору признаков x предсказывает его класс. Если имеется конечная обучающая выборка $U \subset \Omega$, конечная контрольная выборка $\tilde{U} \subset \Omega$ и идеальный оператор $\Phi(x): \Omega \rightarrow [0; L-1] \cap Z$, который ставит в соответствие объекту распознавания его класс, то вероятность ошибки предсказания можно оценить как

$$\varepsilon = \frac{|\{x \in \tilde{U} \mid \Phi(x) \neq \tilde{\Phi}(x)\}|}{|\tilde{U}|}, \quad (2)$$

где $|A|$ – это количество элементов в конечном множестве A .

Тогда под точностью классификации можно понимать долю верно классифицированных объектов из заданной выборки, то есть

$$J = 1 - \varepsilon. \quad (3)$$

Решить задачу отбора признаков – значит найти подмножество признаков $Q \subseteq [1; M] \cap Z$, которое будет обеспечивать максимальное значение точности классификации J , вычисленной по обучающей выборке с помощью кросс-валидации. Нужно отметить, что при использовании такого критерия качества признакового пространства отбор признаков привязан к конкретному классификатору, решающему конечную задачу классификации.

Для решения задачи классификации мы использовали Random Forest Model. Это наиболее универсальный классификатор, хорошо подходящий для решения подобных задач [16].

Методы отбора признаков

Метод прямого отбора признаков [17]. Начинаем с пустого набора признаков $Q_{(0)} = \emptyset$, на шаге i ищем

ошибку (2) для набора признаков с добавленным признаком j и добавляем признак j , для которого эта ошибка минимальна:

$$Q_{(i)} = Q_{(i-1)} \cup \left\{ \underset{j \in [1; m] \cap Z}{\operatorname{argmin}} \varepsilon [Q_{(i-1)} \cup \{j\}] \right\}. \quad (4)$$

Алгоритм завершает работу по достижению необходимого количества признаков.

Метод обратного отбора признаков [18]. Начинаем с набора, состоящего из всех признаков $Q_{(0)} = Q = [1; K] \cap Z$, на шаге i ищем ошибку (2) для набора признаков с удаленным признаком j и удаляем из набора признак j , для которого ошибка минимальна:

$$Q_{(i)} = Q_{(i-1)} \setminus \left\{ \underset{j \in [1; m] \cap Z}{\operatorname{argmin}} \varepsilon [Q_{(i-1)} \setminus \{j\}] \right\}. \quad (5)$$

Алгоритм завершает работу по достижении необходимого количества признаков.

Следуя идее, предложенной в [19], можно синтезировать комбинированный алгоритм отбора признаков, включающий в себя шаги прямого и обратного отбора. Начинаем с набора, состоящего из всех признаков $Q_{(0)} = Q = [1; K] \cap Z$. На шаге i ищем ошибку ε_i для набора признаков с удаленным признаком j (4), после чего удаляем признак, для которого ошибка минимальна. Далее сразу на этом же шаге рассматриваем все наборы признаков (5) с добавленными признаками (j) и вычисляем для них значение ошибки ε_{i+} . Если $\varepsilon_{i+} < \varepsilon_i$, то соответствующий признак j , для которого ошибка ε_{i+} минимальна, добавляется в набор.

Алгоритм останавливается, когда достигается необходимое количество признаков либо когда достигается ограничение на количество итераций.

Рекурсивное удаление признаков [20] – это развитие алгоритма обратного отбора признаков. Начинаем с набора, состоящего из всех признаков $Q_{(0)} = Q = [1; K] \cap Z$, на шаге i ищем, перебираем все подмножества F_i текущего набора признаков Q_i небольшой мощности, не превышающей h . Предсказательная модель обучается на наборе признаков F_i , после чего из набора признаков Q_i удаляется подмножество признаков F_j , для которого ошибка (2) максимальная.

Алгоритм завершает работу по достижению необходимого количества признаков.

Результаты вычислительных экспериментов

Было проведено четыре исследования.

В ходе вычислительных экспериментов, чтобы избежать переобучения, набор данных разделялся на обучающую и контрольную выборку в отношении 80/20. Для разбиения использовалась функция `train_test_split` библиотеки `sklearn` с параметрами `test_size = 0,20` и `random_state = 27`.

Первое исследование заключалось в определении типа новообразования по его изображению.

Средняя точность (3) при полном наборе признаков составила 71 %, с использованием алгоритмов отбора признаков составила 97 %. Сводная диаграмма представлена на рис. 2. Лучшие результаты по алгоритмам представлены в табл. 1, количество признаков, позволяющее получить лучшие результаты, представлено в табл. 2.

Можно заметить, что лучшую точность показали методы прямого отбора признаков и метод рекурсивного удаления. В режимах сканирования C и D удалось достичь 100-процентного результата распознавания.




Рис. 2. Результаты на определение типа менингиомы

Табл. 1. Результаты на определение типа менингиомы, лучшие показатели с использованием алгоритмов

| | C | D | F | T1 | T2 |
|---|------|------|------|------|------|
| Метод прямого отбора признаков | 1 | 0,69 | 0,96 | 0,83 | 0,9 |
| Метод обратного отбора признаков | 0,8 | 0,5 | 0,78 | 0,65 | 0,72 |
| Комбинированный алгоритм отбора признаков | 0,87 | 0,38 | 0,86 | 0,62 | 0,69 |
| Рекурсивное удаление признаков | 0,97 | 1 | 0,96 | 0,97 | 0,97 |

Табл. 2. Результаты на определение типа менингиомы, количество признаков, при котором достигнуты лучшие показатели

| | C | D | F | T1 | T2 |
|---|-----|-----|-----|-----|-----|
| Метод прямого отбора признаков | 10 | 210 | 10 | 240 | 10 |
| Метод обратного отбора признаков | 10 | 270 | 40 | 240 | 250 |
| Комбинированный алгоритм отбора признаков | 198 | 218 | 208 | 218 | 48 |
| Рекурсивное удаление признаков | 10 | 10 | 10 | 10 | 10 |

Второе исследование заключалось в определении необходимости лечения в случае использования двух классов.

Средняя точность при полном наборе признаков составила 52 %, а с использованием алгоритмов отбора признаков составила 69 %. Сводная диаграмма представлена на рис. 3. Лучшие результаты по алгоритмам представлены в табл. 3, количество признаков, позволяющее получить лучшие результаты, представлено в табл. 4.

Можно заметить, что лучшую точность показал метод прямого отбора признаков для режима сканирования F при 100 признаках.




Рис. 3. Результаты определения необходимости лечения для 2 классов

Табл. 3. Результаты определения необходимости лечения для 2 классов, лучшие показатели с использованием алгоритмов

| | C | D | F | T1 | T2 |
|---|------|------|------|------|------|
| Метод прямого отбора признаков | 0,67 | 0,67 | 0,78 | 0,60 | 0,7 |
| Метод обратного отбора признаков | 0,71 | 0,67 | 0,67 | 0,60 | 0,7 |
| Комбинированный алгоритм отбора признаков | 0,67 | 0,67 | 0,67 | 0,60 | 0,7 |
| Рекурсивное удаление признаков | 0,71 | 0,67 | 0,67 | 0,60 | 0,75 |

Табл. 4. Результаты определения необходимости лечения для 2 классов, количество признаков, при котором достигнуты лучшие показатели

| | C | D | F | T1 | T2 |
|---|-----|-----|-----|-----|-----|
| Метод прямого отбора признаков | 30 | 80 | 100 | 10 | 180 |
| Метод обратного отбора признаков | 160 | 150 | 30 | 30 | 50 |
| Комбинированный алгоритм отбора признаков | 47 | 27 | 7 | 247 | 157 |
| Рекурсивное удаление признаков | 80 | 150 | 10 | 10 | 190 |

Третье исследование заключалось в определении необходимости лечения в случае использования 3 классов. Добавились пациенты, для которых результаты лечения не определены.

Средняя точность при полном наборе признаков составила 55 %, с использованием алгоритмов отбора признаков составила 60 %. Сводная диаграмма представлена на рис. 4. Лучшие результаты по алгоритмам представлены в табл. 5, количество признаков, позволяющих получить лучшие результаты, представлено в табл. 6.




Рис. 4. Результаты определения необходимости лечения для 3 классов

Можно заметить, что все алгоритмы показали лучшие результаты для режима сканирования D, од-

нако комбинированный алгоритм достиг результата всего при 127 признаках.

Четвертое исследование заключалось в определении необходимости лечения в случае использования 2 классов, но с добавлением признака, который отвечает за тип менингиомы.

Табл. 5. Результаты определения необходимости лечения для 3 классов, лучшие показатели с использованием алгоритмов

| | C | D | F | T1 | T2 |
|---|------|-------|-------|-------|-------|
| Метод прямого отбора признаков | 0,5 | 0,875 | 0,48 | 0,586 | 0,448 |
| Метод обратного отбора признаков | 0,5 | 0,875 | 0,556 | 0,586 | 0,414 |
| Комбинированный алгоритм отбора признаков | 0,5 | 0,875 | 0,556 | 0,586 | 0,517 |
| Рекурсивное удаление признаков | 0,47 | 0,875 | 0,593 | 0,48 | 0,62 |

Табл. 6. Результаты определения необходимости лечения для 3 классов, количество признаков, при котором достигнуты лучшие показатели

| | C | D | F | T1 | T2 |
|---|----|-----|----|-----|-----|
| Метод прямого отбора признаков | 90 | 200 | 10 | 250 | 10 |
| Метод обратного отбора признаков | 40 | 280 | 40 | 10 | 290 |
| Комбинированный алгоритм отбора признаков | 67 | 127 | 67 | 137 | 295 |
| Рекурсивное удаление признаков | 10 | 180 | 60 | 50 | 30 |

Средняя точность при полном наборе признаков составила 70 %, с использованием алгоритмов отбора признаков составила 100 %. Сводная диаграмма представлена на рис. 5. Лучшие результаты по алгоритмам представлены в табл. 5, количество признаков, позволяющих получить лучшие результаты, представлено в табл. 6.

Можно заметить, что алгоритм прямого отбора признаков и алгоритм рекурсивного отбора признаков позволили выбирать набор признаков, который может однозначно определить их необходимость.

Добавление признака, который отвечает за тип менингиомы, позволил значительно улучшить результат, что отчетливо видно в сравнении табл. 3 и 7.




Рис. 5. Результаты определения необходимости лечения для 2 классов с использованием признака, который отвечает за тип менингиомы

Табл. 7. Результаты определения необходимости лечения с использованием признака, который отвечает за тип менингиомы, лучшие показатели с использованием алгоритмов

| | C | D | F | T1 | T2 |
|---|------|------|------|------|------|
| Метод прямого отбора признаков | 1 | 1 | 1 | 1 | 1 |
| Метод обратного отбора признаков | 1 | 0,78 | 0,83 | 0,85 | 0,95 |
| Комбинированный алгоритм отбора признаков | 0,95 | 0,67 | 0,94 | 0,55 | 0,95 |
| Рекурсивное удаление признаков | 1 | 1 | 1 | 1 | 1 |

Табл. 8. Результаты определения необходимости лечения с использованием признака, который отвечает за тип менингиомы, количество признаков, при котором достигнуты лучшие показатели

| | C | D | F | T1 | T2 |
|---|-----|----|-----|-----|----|
| Метод прямого отбора признаков | 10 | 10 | 10 | 10 | 10 |
| Метод обратного отбора признаков | 190 | 40 | 40 | 60 | 90 |
| Комбинированный алгоритм отбора признаков | 88 | 68 | 268 | 228 | 38 |
| Рекурсивное удаление признаков | 10 | 10 | 10 | 10 | 10 |

Заключение

В данной работе были рассмотрены способы повышения эффективности анализа изображений МРТ головного мозга.

С использованием алгоритмов жадного отбора признаков удалось приблизить результаты определения типа новообразования к 97 %. Для режима сканирования DWI тип новообразования был правильно определен для всех изображений контрольной выборки без исключения.

В исследованиях необходимости лечения наблюдается яркий пик для режима сканирования DWI, точность правильной классификации для него составила 88 %. Однако при исключении из набора данных пациентов, для которых нет явных данных результатов лечения, результат упал до 70 %. Это может быть связано с небольшим объемом выборки.

Лучший результат для двух классов (требуется лечение / лечение не требуется) показал режим сканирования F, с использованием жадных алгоритмов отбора признаков удалось правильно классифицировать 78 % изображений.

Использование текстовых признаков в совокупности с признаком, отвечающим за тип менингиомы, позволило однозначно определить необходимость лечения пациента.

Лучшие результаты при этом достигаются с использованием алгоритма прямого отбора признаков и алгоритма рекурсивного удаления.

References

- [1] Ostrom QT, Patil N, Cioffi G, Waite K, Kruchko C, Barnholtz-Sloan JS. CBTRUS statistical report: Primary brain and other central nervous system tumors diagnosed in the united states in 2013-2017. *Neuro Oncol* 2020; 22(Suppl 2): iv1-iv96. doi: 10.1093/neuonc/noaa200.
- [2] Kholin AV. Magnetic resonance imaging for diseases and injuries of the central nervous system [In Russian]. Moscow: "MEDpress-inform" Publisher; 2017.
- [3] Louis DN, Perry A, Reifenberger G, von Deimling A, Figarella-Branger D, Cavenee WK, Ohgaki H, Wiestler OD, Kleihues P, Ellison DW. The 2016 world health organization classification of tumors of the central nervous system: A summary. *Acta Neuropathol* 2016; 131(6): 803-820. doi: 10.1007/s00401-016-1545-1.
- [4] Goldbrunner R, Minniti G, Preusser M, et al. EANO guidelines for the diagnosis and treatment of meningiomas. *Lancet Oncol* 2016; 17(9): e383-e391. DOI: 10.1016/S1470-2045(16)30321-7.
- [5] Goldbrunner R, Weller M, Regis J, et al. EANO guideline on the diagnosis and treatment of vestibular schwannoma. *Neuro Oncol* 2020; 22(1): 31-45. doi: 10.1093/neuonc/noz153.
- [6] Shabani S, Kaushal M, Kaufman B, et al. Intracranial extra-axial mesenchymal chondrosarcoma: Case report and review of the literature of reported cases in adults and children. *World Neurosurg* 2019; 129: 302-310. doi: 10.1016/j.wneu.2019.05.221.
- [7] Strasilla C, Sychra V. Bildgebende Diagnostik des Vestibularis-schwannoms. *HNO* 2017; 65(5): 373-380. doi: 10.1007/s00106-016-0227-6.
- [8] Kim KH, Kang SJ, Choi JW, et al. Clinical and radiological outcomes of proactive Gamma Knife surgery for asymptomatic meningiomas compared with the natural course without intervention. *J Neurosurg* 2018; 130(5): 1740-1749. doi: 10.3171/2017.12.JNS171943.
- [9] Nasi D, Zunarelli E, Puzzolante A, Moriconi E, Pavesi G. Early life-threatening enlargement of a vestibular schwannoma after gamma knife radiosurgery. *Acta Neurochir (Wien)* 2020; 162(8): 1977-1982. doi: 10.1007/s00701-020-04434-2.
- [10] Kim JH, Jung HH, Chang JH, Chang JW, Park YG, Chang WS. Predictive factors of unfavorable events after gamma knife radiosurgery for vestibular schwannoma. *World Neurosurg* 2017; 107: 175-184. doi: 10.1016/j.wneu.2017.07.139.
- [11] Speckter H, Bido J, Hernandez G, Rivera D, Suazo L, Valenzuela S, Miches I, Oviedo J, Gonzalez C, Stoeter P. Pretreatment texture analysis of routine MR images and shape analysis of the diffusion tensor for prediction of volumetric response after radiosurgery for meningioma. *J Neurosurg* 2018; 129(Suppl 1): 31-37. doi: 10.3171/2018.7.GKS181327.
- [12] Lambin P, Leijenaar RTH, Deist TM, et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nat Rev Clin Oncol* 2017; 14(12): 749-762. doi: 10.1038/nrclinonc.2017.141.
- [13] Agafonova YuD, Gaidel AV, Zelter PM, Kapishnikov AV. Efficiency of machine learning algorithms and convolutional neural network for detecting of pathological changes in MR images of the brain. *Computer Optics* 2020; 44(2): 266-273. DOI: 10.18287/2412-6179-CO-671.
- [14] Wen PY, Chang SM, Van den Bent MJ, Vogelbaum MA, Macdonald DR, Lee EQ. Response assessment in neuro-oncology clinical trials. *J Clin Oncol* 2017; 35(21): 2439-2449. doi: 10.1200/JCO.2017.72.7511.
- [15] Szczypinski PM, Strzelecki M, Materka A. MaZda – a software for texture analysis. *Int Symposium on Information Technology Convergence* 2007: 245-249. DOI: 10.1109/ISITC.2007.15.
- [16] Fernández-Delgado M, Cernadas E, Barro S, Amorim D. Do we need hundreds of classifiers to solve real world classification problems? *J Mach Learn Res* 2014; 15(1): 3133-3181. DOI: 10.5555/2627435.2697065.
- [17] Guyon I, Weston J, Barnhill S, Vapnik V. Gene selection for cancer classification using support vector machines. *Mach Learn* 2002; 46(1-3): 389-422. DOI: 10.1023/A:1012487302797.
- [18] Couvreur C, Bresler Y. On the optimality of the back-ward greedy algorithm for the subset selection problem. *SIAM J Matrix Anal Appl* 2000; 21(3): 797-808. DOI: 10.1137/S089547989832928.
- [19] Goncharova EF, Gaidel AV. Greedy algorithms of feature selection for multiclass image classification. *CEUR Workshop Proceedings* 2018; 2210: 38-46.
- [20] Marcano-Cedeño A, Quintanilla-Domínguez J, Cortina-Januchs MG, Andina D. Feature selection using sequential forward selection and classification applying artificial metaplasticity neural network. *IECON 2010 – 36th Annual Conf on IEEE Industrial Electronics* 2010: 2845-2850. DOI: 10.1109/IECON.2010.5675075.

Сведения об авторах

Коневский Владислав Валерьевич, 1996 года рождения, в 2020 году окончил магистратуру Самарского национального исследовательского университета имени академика С.П. Королева по специальности 01.04.02 «Прикладная математика и информатика», работает разработчиком в ПАО «Мегафон». Область научных интересов: обработка изображений, программирование. E-mail: konevskiyvladislav@gmail.com.

Благов Александр Владимирович, 1985 года рождения, кандидат технических наук, в 2008 году окончил Самарский государственный аэрокосмический университет имени академика С.П. Королёва по направлению «Прикладная математика и информатика», в 2011 году защитил кандидатскую диссертацию. Работает доцентом кафедры технической кибернетики Самарского университета. Область научных интересов: интеллектуальный анализ данных, анализ данных социальных сетей, теория алгоритмов. E-mail: blagov@ssau.ru.

Гайдель Андрей Викторович, 1989 года рождения, кандидат технических наук, в 2012 году окончил Самарский государственный аэрокосмический университет имени академика С.П. Королёва по направлению «Прикладная математика и информатика», в 2015 году защитил кандидатскую диссертацию. Работает доцентом кафедры технической кибернетики Самарского университета и научным сотрудником в Институте систем об-

работки изображений РАН – филиале ФНИЦ «Кристаллография и фотоника» РАН. Область научных интересов: компьютерная обработка изображений, теория распознавания образов, интеллектуальный анализ данных, теория алгоритмов. E-mail: andrey.gaidel@gmail.com.

Капишников Александр Викторович, 1955 года рождения, д.м.н., доцент. В 1972 году окончил лечебный факультет Куйбышевского медицинского института. Докторскую диссертацию защитил в 2004 году. Заведует кафедрой лучевой диагностики и лучевой терапии ФГБОУ ВО СамГМУ Минздрава России. Область научных интересов: лучевая диагностика и ядерная медицина, информационные технологии медицинской радиологии, CADe и CADx-системы для поддержки. E-mail: a.kapishnikov@gmail.com.

Куприянов Александр Викторович, профессор кафедры технической кибернетики Самарского национального исследовательского университета имени академика С.П. Королёва; старший научный сотрудник лаборатории математических методов обработки изображений Института систем обработки изображений РАН – филиала ФНИЦ «Кристаллография и фотоника» РАН. Сфера научных интересов: цифровая обработка сигналов и изображений; распознавание образов и искусственный интеллект; анализ и интерпретация биомедицинских сигналов и изображений. E-mail: alexkupr@gmail.com.

Суровцев Евгений Николаевич, 1987 года рождения, учился в Самарском государственном медицинском университете. Работает ассистентом кафедры лучевой диагностики и лучевой терапии. ФГБОУ ВО СамГМУ Минздрава России и заведующим отделением магнитно-резонансной томографии ООО «ЛДЦ МИБС – Тольятти». Область научных интересов: лучевая диагностика, магнитно-резонансная томография, онкология, обработка изображений. E-mail: evgeniisurovcev@mail.ru.

Асатрян Давид Гегамович, 1940 года рождения, доктор технических наук, профессор, работает руководителем Научно-исследовательского центра критических технологий Российско-Армянского (Славянского) университета и ведущим научным сотрудником в Институте проблем информатики и автоматизации национальной академии наук Армении. Область научных интересов: обработка сигналов и изображений. E-mail: dasat@ipia.sci.am.

ГРНТИ: 28.23.15

Поступила в редакцию 3 сентября 2021 г. Окончательный вариант – 21 ноября 2021 г.

Improving the efficiency of brain MRI image analysis using feature selection

V.V. Konevsky¹, A.V. Blagov¹, A.V. Gaidel^{1,2}, A.V. Kapishnikov³,

A.V. Kupriyanov¹, E.N. Surovtsev³, D.G. Asatryan^{4,5}

¹ Samara National Research University, 443086, Samara, Russia, Moskovskoye Shosse 34,

² IPSI RAS – Branch of the FSRC “Crystallography and Photonics” RAS,
443001, Samara, Russia, Molodogvardeyskaya 151,

³ Federal State Budgetary Educational Institution of Higher Education “Samara State Medical University”
of the Ministry of Health of the Russian Federation, 443099, Russia, Samara, st. Chapaevskaya, 89,

⁴ Russian-Armenian University, Armenia, Yerevan,

⁵ Institute for Informatics and Automation Problems of National Academy of Sciences of Armenia, Armen

Abstract

This article discusses the possibility of improving the quality of analysis of MRI images of the brain in various scanning modes by using greedy feature selection algorithms. A total of five MRI sequences were reviewed. The texture features were formed using the MaZda software package. Using an algorithm for recursive feature selection, the accuracy of determining the type of tumor can be increased from 69 % to 100 %. With the help of the combined algorithm for the selection of signs, it was possible to increase the accuracy of determining the need for treatment of a patient from 60 % to 75 % and from 81 % to 88 % in the case of using an additional class of data for patients whose accurate result of treatment is unknown. The use of textural features in combination with a feature that is responsible for the type of meningioma made it possible to unambiguously determine the need for patient treatment.

Keywords: texture analysis, computer optics, image processing, greedy algorithms, MRI diagnostics, meningioma.

Citation: Konevsky VV, Blagov AV, Gaidel AV, Kapishnikov AV, Kupriyanov AV, Surovtsev EN, Asatryan DG. Improving the efficiency of brain MRI image analysis using feature selection. *Computer Optics* 2022; 46(4): 621-627. DOI: 10.18287/2412-6179-CO-1040.

Acknowledgements: Theoretical studies were carried out with the support of the RFBR grant No. 19-29-01235 MK. The experimental results were obtained with the support of the Russian Foundation for Basic Research and RA Science Committee in the frames of the joint research project RFBR 20-51-05008 Arm_a and SCS 20RF-144 accordingly.

Authors' information

Vladislav Valerievich Konevsky (b. 1996). In 2020 graduated from the Samara National Research University named after academician S.P. Korolyov, specialty 01.04.02 "Applied Mathematics and Informatics", works as a developer at PJSC "Megafon". Research interests: image processing, programming. E-mail: konevskiyvladislav@gmail.com.

Alexander Vladimirovich Blagov (b. 1985) graduated from Samara State Aerospace University in 2008, majoring in Applied Mathematics and Informatics. He received his candidate's degree in Technical Science in 2011. Associate professor of the Technical Cybernetics department of Samara National Research University. His research interests currently focus on data mining, social network analysis, theory of computation. E-mail: blagov@ssau.ru.

Andrey Viktorovich Gaidel (b. 1989). Graduated from Samara State Aerospace University in 2012, majoring in Applied Mathematics and Informatics. He received his Candidate of Science degree in Physics and Math in 2015 from the SSAU. Currently he is a teaching assistant of the Technical Cybernetics sub-department and Engineer at SSAU's laboratory SRL-35 of Samara State Aerospace University, also working as an intern researcher of the Image Processing Systems Institute of the Russian Academy of Sciences – Branch of the FSRC “Crystallography and Photonics” RAS, Samara, Russia. His research interests currently focus on computer image processing, pattern recognition, data mining and theory of computation. E-mail: andrey.gaidel@gmail.com.

Aleksandr Viktorovich Kapishnikov (b. 1955). In 1972 he graduated from the Medical faculty of the Kuibyshev Medical Institute. Doctor of Science in Medicine (2004). Head of Diagnostic Radiology and Medical Informatics department of Samara State Medical University. Research interests: diagnostic radiology and nuclear medicine in pulmonology, osteology, nephrology and oncology, information technology in medical imaging, computer-based diagnostic support system (CADe and CADx). E-mail: a.kapishnikov@gmail.com.

Alexandr Victorovich Kupriyanov (b. 1978), graduated (2001) from the S.P. Korolyov Samara State Aerospace University (SSAU). He received his PhD in Technical Sciences (2004). At present he is a senior researcher at the IPSI RAS – Branch of the FSRC “Crystallography and Photonics” RAS, and holding a part-time position of Associate Professor at Technical Cybernetics department of Samara University. The area of interests includes digital signals and image processing, pattern recognition and artificial intelligence, biomedical imaging and analysis. His list of publications contains more than 80 scientific papers, including 35 articles and 1 monograph published.

E-mail: alexkupr@gmail.com.

Evgeny Nikolaevich Surovtsev (b. 1987). Studied at Samara State Medical University. Works as an assistant at Radiation Diagnostics and Radiation Therapy department. FSBEI HE SamSMU of the Ministry of Health of Russia and the head of Magnetic Resonance Imaging department of LLC MDTs MIBS - Togliatti. Research interests: radiation diagnostics, magnetic resonance imaging, oncology, image processing.

E-mail: evgeniisurovcev@mail.ru.

David G. Asatryan (b. 1940). Doctor of Sciences (Engineering), professor, he works as a Head of Center for Critical Technologies of the Russian-Armenian (Slavonic) University and as a leading scientific worker at the Institute for Problems of Informatics and Automation of National Academy of Sciences of Armenia. Research interest: signal and image processing. E-mail: dasat@ipia.sci.am.

Received September 3, 2021. The final version – November 21, 2021.
