

УДК 004.85

КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ ПЕРВИЧНЫХ ЭЛЕМЕНТОВ КОЖНОЙ СЫПИ

Т.А. Полевая^a, И.А. Сaitов^a, Р.А. Раводин^b, А.А. Фильченков^a

^a Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

^b Северо-Западный государственный медицинский университет имени И.И. Мечникова, Санкт-Петербург, 191015, Российская Федерация

Адрес для переписки: tanusha2406@gmail.com

Информация о статье

Поступила в редакцию 25.12.18, принята к печати 11.02.19

doi: 10.17586/2226-1494-2019-19-2-333-338

Язык статьи – русский

Ссылка для цитирования: Полевая Т.А., Сaitов И.А., Раводин Р.А., Фильченков А.А. Классификация изображений первичных элементов кожной сыпи // Научно-технический вестник информационных технологий, механики и оптики. 2019. Т. 19. № 2. С. 333–338. doi: 10.17586/2226-1494-2019-19-2-333-338

Аннотация

Рассмотрена задача классификации изображений методами глубокого обучения для выявления первичных морфологических элементов кожной сыпи. Одним из перспективных направлений повышения качества медицинской помощи больным дерматовенерологического профиля является создание информационно-диагностических систем и систем поддержки принятия решений. В качестве одного из компонентов таких систем может выступать модуль автоматического определения первичных элементов сыпи на изображениях пораженных участков кожи. Предложен метод глубокого обучения и переноса знаний для классификации изображений первичных элементов кожной сыпи. Проанализирована зависимость точности получаемого классификатора изображений кожной сыпи от алгоритма обучения нейронных сетей. Приведены результаты экспериментов по применению метода для классификации следующих первичных элементов: гнойничок, пятно, узел, папула, плоская бляшка. Алгоритм, реализующий метод, показал точность 76,00 % на 5 классах первичных элементов кожной сыпи (гнойничок, пятно, узел, папула, плоская бляшка), 77,50 % на 4 классах (пятно, узел, папула, плоская бляшка) и 81,67 % на 3 классах (узел, папула, плоская бляшка).

Ключевые слова

кожное заболевание, первичные морфологические элементы кожной сыпи, перенос знаний, машинное обучение, автоматическая диагностика, VGG16

Благодарности

Исследования проводились при поддержке Правительства РФ, грант 08-08, и Фонда содействия инновациям, НИОКР 2219ГС1/37055.

IMAGE CLASSIFICATION OF PRIMARY MORPHOLOGICAL ELEMENTS OF SKIN LESIONS

T.A. Poleyaya^a, I.A. Saitov^a, R.A. Ravodin^b, A.A. Filchenkov^a

^aITMO University, Saint Petersburg, 197101, Russian Federation

^bNorth-Western State Medical University named after I.I. Mechnikov, Saint Petersburg, 191015, Russian Federation

Corresponding author: tanusha2406@gmail.com

Article info

Received 25.12.18, accepted 11.02.19

doi: 10.17586/2226-1494-2019-19-2-333-338

Article in Russian

For citation: Poleyaya T.A., Saitov I.A., Ravodin R.A., Filchenkov A.A. Image classification of primary morphological elements of skin lesions. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2019, vol. 19, no. 2, pp. 333–338 (in Russian). doi: 10.17586/2226-1494-2019-19-2-333-338

Abstract

We consider the problem of image classification by deep learning methods for solving classification task for primary morphological elements of skin lesions. The creation of clinical decision support systems becomes one of the promising directions of improving the quality of medical care for patients with dermatovenerological profile. A module of automatic detection of primary morphological elements of skin lesions on skin lesion images can be considered as one of the components of such systems. This study proposes a solution for the problem of primary morphological elements

classification based on deep learning and transfer learning. We compare the effect of different learning algorithms application on the accuracy of resulting skin lesion images classifier. We provide experimental results on application of suggested solution to the following primary morphological elements: pustule, macule, nodule, papule and plaque. The proposed algorithm showed 76.00 % accuracy for 5 classes of primary morphological elements (pustule, macule, nodule, papule and plaque), 77.50 % accuracy for 4 classes (macule, nodule, papule and plaque) and 81.67 % accuracy for 3 classes (nodule, papule and plaque).

Keywords

skin disease, primary morphology of skin lesions, transfer learning, machine learning, automatic diagnostics, VGG16

Acknowledgements

The research was supported by the Government of the Russian Federation, Grant 08-08, and FASIE, R&D 2219GS1/37055.

Введение

Качество медицинской помощи населению в значительной степени зависит от компетентности врачебного персонала. Проблема врачебных ошибок стоит достаточно остро в медицине, в том числе в дерматовенерологии, что обуславливает необходимость разработки эффективных мер их профилактики. Одним из перспективных направлений повышения качества медицинской помощи больным дерматовенерологического профиля является создание интеллектуальных информационно-диагностических (ИИД) и обучающих систем поддержки принятия решений (СППР).

Особенностью дерматологических заболеваний является то, что множество симптомов проявляются в виде поражений кожи и доступны для визуального анализа. Вследствие этого в ИИД и СППР возможно использовать компонент автоматизированной диагностики кожного заболевания по изображению.

Большая часть научных работ в области автоматической диагностики кожных заболеваний посвящена проблеме выявления злокачественных новообразований [1–3]. Диагностирование других дерматологических заболеваний пока вызывает меньший интерес.

Некоторые исследователи пытались классифицировать изображения по представленным на них кожным заболеваниям. Данная задача сложна из-за большого числа кожных заболеваний, поэтому ее упрощают путем выбора небольшого подмножества заболеваний (от 3 до 9) [4–6]. Перспективным подходом к решению является идентификация морфологических элементов пораженных участков кожи [5] для последующего использования в диагностике [7]. Преимуществом этого подхода является небольшое число видов первичных элементов по сравнению с числом выделяемых заболеваний.

Чем сложнее задача классификации, тем больше необходимо используемых для обучения размеченных данных. Однако доступность размеченных медицинских данных является одной из общепризнанных проблем.

Морфологические элементы делят на первичные и вторичные [8]. Первичная морфология характеризует внешние признаки кожного поражения, в то время как вторичная – изменения кожного поражения с течением времени [9]. Таким образом, первичные морфологические признаки более значимы для диагностики дерматологических заболеваний, поэтому задача определения первичных морфологических элементов является более приоритетной.

В [10] предложено решение проблемы классификации изображений четырех морфологических элементов: пятно (macule), папула (papule), узел (nodule), плоская бляшка (plaque). Решение состояло в применении классификатора (в исследовании были рассмотрены: метод *k*-ближайших соседей, дерево принятия решений, многослойный перцептрон и метод опорных векторов) к специально подобранным признакам изображений, характеризующим цвет, форму и текстуру изображения. Такое решение позволило им получить точность 65,63 % на четырех классах и 70,71 % – на трех.

Используемые данные

Общедоступных наборов данных, содержащих размеченные первичные морфологические элементы сыпей, не существует.

В связи со сложностью сбора данных реальных пациентов было принято решение найти нужные данные в Интернете.

Релевантные изображения удалось найти при помощи сервиса Google Images, используя поисковые запросы «skin macule», «skin skin», «skin papule», «skin plaque», «skin pustule». Для скачивания изображений, выдаваемых сервисом, была использована библиотека Selenium Webdriver¹, позволяющая эмулировать действия пользователя. По перечисленным выше запросам удалось загрузить от 600 до 800 изображений на класс. После удаления картинок, не являющихся изображениями кожи, осталось от 275 до 509 изображений на класс.

Затем набор данных был разбит на тренировочное и валидационное множества. Для повышения

¹ <https://pypi.org/project/selenium/>

достоверности работы алгоритма валидационное множество (20 изображений на класс) было сформировано специалистом-дерматологом. Затем дубликаты валидационных изображений были найдены и удалены из тренировочного множества при помощи детектора особых точек Oriented FAST and Rotated BRIEF (ORB) [11].

Метки обучающей части набора данных были зашумлены, метки объектов валидационной части были надежны, что и обеспечило корректность результатов работы классификаторов.

Классификация изображений первичных морфологических элементов сыпей

Из-за нехватки данных сложно добиться высокого качества модели, обучая ее с нуля. Для преодоления этой проблемы была использована техника переноса знаний (transfer learning) [12]. Ее основная идея заключается в том, что алгоритм, обученный обрабатывать объекты из домена A , может иметь некоторые данные о домене B , если домены A и B похожи. Адаптация такого алгоритма для применения к объектам из домена B потребует меньше данных, потому что алгоритму будет достаточно узнать информацию о B , не содержащуюся в домене A .

Перенос знаний широко используется в компьютерном зрении, так как домены изображений имеют много схожих черт, связанных с их структурой. Как следствие, нейронная сеть, предварительно обученная на изображениях одного рода, может быть переобучена различать изображения второго рода на меньшем их числе.

В качестве основы для классификатора использована архитектура VGG16-D [13]. Нижние уровни нейронной сети можно разделить на пять однородных блоков. Каждый блок включает в себя несколько сверточных слоев с функцией активации ReLU, за которыми следует понижающий размерность слой пулинга с функцией максимума. За блоками нижних уровней следуют три полносвязных слоя и слой softmax, выполняющий классификацию.

Хотя архитектура VGG16 уступает многим более современным архитектурам глубоких нейронных сетей по качеству классификации изображений, ее часто используют при переносе знаний [12]. Распространенным сценарием является адаптация VGG16-D, обученной на большой коллекции изображений общего назначения, ImageNet¹, к определенной области [14, 15].

Чтобы адаптировать нейронную сеть, предобученную на ImageNet, последний слой нейронной сети заменен на соответствующий нужному количеству классов, полученная нейронная сеть дообучена на собранных данных кожных поражений (рис. 1).




Рис. 1. Архитектура нейронной сети

Обучение на собранных данных проводилось в несколько этапов. Для начала был обучен только верхний слой с сохранением весов предыдущих слоев. Затем обучены все слои – с меньшей скоростью обучения для нижних и большей для верхних (рис. 2). Для достижения устойчивого локального минимума использована техника Stochastic Gradient Descent with Warm Restarts (SGDR) [16]. На рис. 3 приведен график изменения скорости обучения верхних слоев на протяжении одного цикла SGDR.

¹ <http://www.image-net.org/>

Базовая скорость обучения выбрана за счет постепенного увеличения функции потерь [17]. Для дообучения нейронной сети использована библиотека fastai¹.

Чтобы компенсировать небольшой размер набора, использована аугментация данных, включающая в себя вращение, отражение, масштабирование и изменение цвета изображений.




Рис. 2. Значения базовой скорости обучения различных слоев нейронной сети




Рис. 3. Изменение скорости обучения верхних слоев нейронной сети на протяжении одного цикла SGDR

Вычислительные эксперименты

Предложенный алгоритм классификации был применен к задачам классификации изображений 3 (узел, папула, плоская бляшка), 4 (пятно, узел, папула, плоская бляшка) и 5 классов (гноинчик, пятно, узел, папула, плоская бляшка).

Применение различных способов обучения показало, что наилучшим подходом является переобучение всех слоев нейронной сети, предобученной на ImageNet, с разной скоростью обучения: более низкой для более нижних слоев и более высокой для верхних. Точность, достигнутая этим методом, выше как точности, получаемой при обучении только верхнего слоя, так и получаемой при обучении всех слоев нейронной сети с одинаковой скоростью (см. таблицу).

Таблица. Сравнение точности различных методов обучения

Число классов	Точность метода обучения, %		
	верхний слой	все слои, одинаковая скорость	все слои, разная скорость
5	59,00	58,00	76,00
4	65,00	57,50	77,50
3	71,00	71,00	81,67

Причиной достижения меньшей точности при обучении только верхнего слоя является различие

¹ <https://github.com/fastai/fastai>

исходного домена ImageNet и целевой области изображений кожных поражений: ImageNet состоит из изображений, содержащих объекты и сцены реальной жизни, тогда как структура кожных поражений схожа с текстурой. При обучении всех слоев с одинаковой скоростью скорость обучения верхних слоев недостаточна, чрезмерное изменение весов нижних слоев, приводя к переобучению, ухудшает результат.

Подход глубокого обучения демонстрирует несколько преимуществ по сравнению с результатами, которые удалось получить при помощи применения методов машинного обучения к выбранным вручную признакам [10]. Во-первых, предлагаемая модель способна достичь более высокой точности для 4 классов – 77,50 против 65,63 %, для 3 – 81,67 против 70,71 %. Во-вторых, предложенный алгоритм позволяет работать со всеми скачанными изображениями кожных поражений и не исключать фотографии, содержащие неровности поверхности кожи или имеющие нечеткие границы пораженного участка.

Как показали результаты обучения нейронной сети, больше всего ошибок происходит на классе папул. Плоские бляшки, как оказалось, легче всего отличить от других первичных морфологических элементов, несмотря на то что этот класс был наименее представлен в тренировочных данных. Трудность при отделеции папул от узлов может быть вызвана тем, что главным различием данных классов является диаметр пораженного участка кожи: элемент кожной сыпи, возвышающийся над поверхностью кожи и плотный при пальпации, называется папулой, если его диаметр не превышает 0,5 см, и узлом в противном случае. Ошибки между классами папул и пятен могут быть связаны с тем, что разница между ними состоит в наличии или отсутствии возвышения над поверхностью кожи, что сложно определить по двумерной картинке. Добавление дополнительного класса (гнойничок) незначительно снижает точность.

Заключение

Проведенное исследование показало возможность успешного применения методов глубокого обучения к решению задачи классификации первичных морфологических элементов сыпей.

Предложенный в работе метод показал схожие и даже превосходящие результаты по сравнению с методами машинного обучения для выбранных вручную признаков цвета, текстуры и формы [10]: точность 77,50 против 65,63 % для 4 классов и 81,67 против 70,71 % для 3 классов. Также добавление еще одного класса – гнойничка – уменьшило точность всего лишь на 1,50 %.

Дополнительным преимуществом предложенного в работе метода является отсутствие необходимости ручной предварительной обработки изображений (удаления изображений с неровной поверхностью кожи или с нечеткой границей пораженного участка, нормализации освещенности).

Одним из возможных направлений дальнейших исследований является применение предложенного метода к большему числу типов первичных морфологических элементов. Другое направление заключается в решении проблемы многозначной классификации первичной морфологии, поскольку пораженные участки кожи могут содержать более одного первичного элемента. Используемая архитектура нейронной сети может быть легко приспособлена для решения задачи многозначной классификации. Однако возможность такого исследования сильно зависит от возможности сбора маркированных данных. Еще одним возможным направлением дальнейших исследований является использование полученного алгоритма как модуля информационно-диагностических и обучающих систем поддержки принятия решений.

Литература

1. Esteva A., Kuprel B., Novoa R.A., Ko J., Swetter S.M., Blau H.M., Thrun S. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*. 2017. V. 542. N 7639. P. 115–118. doi: 10.1038/nature21056
2. Gutman D., Codella N.C.F., Celebi M.E., Helba B., Marchetti M.A. et al. Skin lesion analysis toward melanoma detection: a challenge at the international symposium on biomedical imaging (ISBI) 2016, hosted by the international skin imaging collaboration (ISIC) // *arXiv.org*, arXiv:1605.01397.
3. Codella N.C.F., Gutman D., Celebi M.E., Helba B., Marchetti M.A., Dusza S.W., Kalloo A., Liopyris K., Mishra N.K., Kittler H., Halpern A. Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC) // *Proc. IEEE 15th Int. Symposium on Biomedical Imaging*. Washington, 2018. doi: 10.1109/isbi.2018.8363547
4. Ambad P.S., Shirsat A.S. A image analysis system to detect skin diseases // *IOSR Journal of VLSI and Signal Processing*. 2016. V. 6. N 5. P. 17–25. doi: 10.9790/4200-0605011725
5. Arifin M.S., Kibria M.G., Firoze A. et al. Dermatological disease diagnosis using color-skin images // *International*

References

1. Esteva A., Kuprel B., Novoa R.A., Ko J., Swetter S.M., Blau H.M., Thrun S. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, vol. 542, no. 7639, pp. 115–118. doi: 10.1038/nature21056
2. Gutman D., Codella N.C.F., Celebi M.E., Helba B., Marchetti M.A. et al. Skin lesion analysis toward melanoma detection: a challenge at the international symposium on biomedical imaging (ISBI) 2016, hosted by the international skin imaging collaboration (ISIC). *arXiv.org*, arXiv:1605.01397.
3. Codella N.C.F., Gutman D., Celebi M.E., Helba B., Marchetti M.A., Dusza S.W., Kalloo A., Liopyris K., Mishra N.K., Kittler H., Halpern A. Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC). *Proc. IEEE 15th Int. Symposium on Biomedical Imaging*. Washington, 2018. doi: 10.1109/isbi.2018.8363547
4. Ambad P.S., Shirsat A.S. A image analysis system to detect skin diseases. *IOSR Journal of VLSI and Signal Processing*, 2016, vol. 6, no. 5, pp. 17–25. doi: 10.9790/4200-0605011725
5. Arifin M.S., Kibria M.G., Firoze A. et al. Dermatological disease diagnosis using color-skin images. *International*

- Conference on Machine Learning and Cybernetics. 2012. V. 5. P. 1675–1680. doi: 10.1109/icmlc.2012.6359626
6. Yasir N.A.R., Ashiqur R. Dermatological disease detection using image processing and artificial neural network // Proc. 8th Int. Conf. on Electrical and Computer Engineering. Dhaka, Bangladesh, 2015. P. 687–690. doi: 10.1109/icece.2014.7026918
 7. Goldsmith L., Katz S., Gilchrest B., Paller A., Leffell D., Wolff K. *Fitzpatrick's Dermatology in General Medicine*. 7th ed. NY: McGraw-Hill, 2008.
 8. James W.D., Berger T.G., Elston D. (eds) *Andrews' Diseases of the Skin*. 11th ed. Saunders, 2011.
 9. Bologna J.L., Jorizzo J.J., Schaffer J.V., Callen J.P., Cerroni L. et al. *Dermatology*. 4th ed. Elsevier, 2012.
 10. Macatangay J.M.A., Ruiz C.R., Usatine R.P. A primary morphological classifier for skin lesion images [Электронный ресурс]. Режим доступа: <http://wscg.zcu.cz/wscg2017/full/I37-full.PDF>, свободный. Яз. англ. (дата обращения 15.12.2018).
 11. Rublee E., Rabaud V., Konolige K., Bradski G. ORB: an efficient alternative to SIFT or SURF // Proc. IEEE Int. Conf. on Computer Vision. Barcelona, Spain, 2011. P. 2564–2571. doi: 10.1109/iccv.2011.6126544
 12. Olivas E.S., Guerrero J.D., Sober M.M. et al. *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques*. New York: Information Science Reference, 2010.
 13. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // CoRR. 2015. arXiv:1409.1556
 14. Shin H.C., Roth H., Gao M., Lu L., Xu Z., Nogues I., Yao J., Mollura D.J., Summers R.M. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning // IEEE Transactions on Medical Imaging. 2016. V. 35. N 5. P. 1285–1298. doi: 10.1109/tmi.2016.2528162
 15. Xie S.M., Jean N., Burke M., Lobell D.B., Ermon S. Transfer learning from deep features for remote sensing and poverty mapping // CoRR. 2016. arXiv:1510.00098
 16. Loshchilov I., Hutter F. SGDR: stochastic gradient descent with restarts // Proc. Int. Conf. on Learning Representations. Toulon, France, 2017.
 17. Smith L.N. No more pesky learning rate guessing games // CoRR. 2015. arXiv:1506.01186.
- Conference on Machine Learning and Cybernetics*, 2012, vol. 5, pp. 1675–1680. doi: 10.1109/icmlc.2012.6359626
6. Yasir N.A.R., Ashiqur R. Dermatological disease detection using image processing and artificial neural network. *Proc. 8th Int. Conf. on Electrical and Computer Engineering*. Dhaka, Bangladesh, 2015, pp. 687–690. doi: 10.1109/icece.2014.7026918
 7. Goldsmith L., Katz S., Gilchrest B., Paller A., Leffell D., Wolff K. *Fitzpatrick's Dermatology in General Medicine*. 7th ed. NY, McGraw-Hill, 2008.
 8. James W.D., Berger T.G., Elston D. (eds) *Andrews' Diseases of the Skin*. 11th ed. Saunders, 2011.
 9. Bologna J.L., Jorizzo J.J., Schaffer J.V., Callen J.P., Cerroni L. et al. *Dermatology*. 4th ed. Elsevier, 2012.
 10. Macatangay J.M.A., Ruiz C.R., Usatine R.P. *A primary morphological classifier for skin lesion images*. Available at: <http://wscg.zcu.cz/wscg2017/full/I37-full.PDF> (accessed 15.12.2018).
 11. Rublee E., Rabaud V., Konolige K., Bradski G. ORB: an efficient alternative to SIFT or SURF. *Proc. IEEE Int. Conf. on Computer Vision*. Barcelona, Spain, 2011, pp. 2564–2571. doi: 10.1109/iccv.2011.6126544
 12. Olivas E.S., Guerrero J.D., Sober M.M. et al. *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques*. New York, Information Science Reference, 2010.
 13. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *CoRR*, 2015, arXiv:1409.1556
 14. Shin H.C., Roth H., Gao M., Lu L., Xu Z., Nogues I., Yao J., Mollura D.J., Summers R.M. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Transactions on Medical Imaging*, 2016, vol. 35, no. 5, pp. 1285–1298. doi: 10.1109/tmi.2016.2528162
 15. Xie S.M., Jean N., Burke M., Lobell D.B., Ermon S. Transfer learning from deep features for remote sensing and poverty mapping. *CoRR*, 2016, arXiv:1510.00098
 16. Loshchilov I., Hutter F. SGDR: stochastic gradient descent with restarts. *Proc. Int. Conf. on Learning Representations*. Toulon, France, 2017.
 17. Smith L.N. No more pesky learning rate guessing games. *CoRR*, 2015, arXiv:1506.01186.

Авторы

Полевая Татьяна Андреевна – аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, Scopus ID: 57193708570, ORCID ID: 0000-0001-6131-0019, tanusha2406@gmail.com

Саитов Ирек Аликович – студент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, ORCID ID: 0000-0002-2805-1323, xanilegendx@gmail.com

Раводин Роман Анатольевич – кандидат медицинских наук, доцент, Северо-Западный государственный медицинский университет имени И.И. Мечникова, Санкт-Петербург, 191015, Российская Федерация, ORCID ID: 0000-0002-0737-0317, rracad@mail.ru

Фильченков Андрей Александрович – кандидат физико-математических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, Scopus ID: 55507568200, ORCID ID: 0000-0002-1133-8432, afilechenkov@corp.mail.ru

Authors

Tatyana A. Polevaya – postgraduate, ITMO University, Saint Petersburg, 197101, Russian Federation, Scopus ID: 57193708570, ORCID ID: 0000-0001-6131-0019, tanusha2406@gmail.com

Irek A. Saitov – student, ITMO University, Saint Petersburg, 197101, Russian Federation, ORCID ID: 0000-0002-2805-1323, xanilegendx@gmail.com

Roman A. Ravodin – PhD, Associate Professor, North-Western State Medical University named after I.I. Mechnikov, Saint Petersburg, 191015, Russian Federation, ORCID ID: 0000-0002-0737-0317, rracad@mail.ru

Andrey A. Filchenkov – PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, Scopus ID: 55507568200, ORCID ID: 0000-0002-1133-8432, afilechenkov@corp.mail.ru