

ПРОБЛЕМЫ СОЗДАНИЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ ОСЛОЖНЕНИЙ ПРИ ПЕРИТОНИТЕ НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

PROBLEMS OF CREATING SYSTEMS FOR PREDICTING COMPLICATIONS IN PERITONITIS BASED ON MACHINE LEARNING METHODS

D. Sukhoi
M. Polidanov
M. Barulina
V. Maslyakov
A. Parshin
K. Volkov

Summary. Early detection and prevention of complications remain a challenge due to individual patient characteristics and complex interaction of various risk factors. *The purpose of the study.* To investigate different approaches to develop a system for predicting complications arising from peritonitis using machine learning algorithms. *Materials and methods of research.* Data from 1558 patients hospitalized with the diagnosis of peritonitis were examined. The mean age was 44 ± 8 years. To achieve the goal, a subtask was solved to find exactly those indicators that influenced the occurrence of complications. The constructed model showed good predictive ability in predicting the occurrence or non-occurrence of complications. In search of a reliable predictive model, we evaluated three most dissimilar and generally recognized as the most effective algorithms of classical machine learning: K-nearest neighbors (KNN), support vector machines (SVM), and gradient boosting on decision trees. *Results.* So, we investigated different approaches for developing a system for predicting the probability of peritonitis complication probability by artificial intelligence methods. For the problem at hand, the most effective algorithm was found to be KNN, which was tuned using cross-validation and grid-based hyperparameter search. *Conclusion.* As future work, the model should continue to be monitored and updated to reflect changing trends in data and medical practice. The study demonstrates the potential of using machine learning algorithms to improve the prediction of complications of peritonitis, thereby helping to improve the quality of patient care and treatment.

Keywords: peritonitis; early detection of complications; prediction of complications; machine learning.

Сухой Даниил Владимирович

ФГАОУ ВО «Пермский государственный национальный
исследовательский университет»

Полиданов Максим Андреевич

специалист научно-исследовательского отдела,
ассистент, Университет «Реавиз», г. Санкт-Петербург;
аспирант,

Медицинский университет «Реавиз», г. Саратов
maksim.polidanoff@yandex.ru

Барулина Марина Александровна

д.ф.-м.н., профессор, профессор, Медицинский
университет «Реавиз», г. Саратов

д.ф.-м.н., директор Физико-математического
института, ФГАОУ ВО «Пермский государственный
национальный исследовательский университет»;
заведующий лабораторией «Анализ и синтез
динамических систем в прецизионной механике»,

Саратовский научный центр РАН, Институт проблем
точной механики и управления РАН

Масляков Владимир Владимирович

д.м.н., профессор, профессор, ФГБОУ ВО
«Саратовский государственный медицинский
университет им. В.И. Разумовского» Минздрава России;
д.м.н., профессор, профессор, Медицинский университет
«Реавиз», г. Саратов

Паршин Алексей Владимирович

к.м.н., доцент, доцент, ФГБОУ ВО
«Саратовский государственный медицинский
университет им. В.И. Разумовского» Минздрава России

Волков Кирилл Андреевич

ФГБОУ ВО «Саратовский государственный медицинский
университет им. В.И. Разумовского» Минздрава России

Аннотация. Раннее выявление и профилактика осложнений остаются сложной задачей из-за индивидуальных особенностей пациента и сложного взаимодействия различных факторов риска. *Цель исследования.* Исследование различных подходов для разработки системы прогнозирования осложнений, возникающих при перитоните, с использованием алгоритмов машинного обучения. *Материалы и методы исследования.* Были исследованы данные 1558 пациентов, которых госпитализировали с диагнозом перитонит. Средний возраст — 44 ± 8 лет. Для достижения поставленной цели была решена подзадача нахождения именно тех показателей, которые влияли на возникновение осложнений. Построенная модель показала хорошую предсказательную способность по предсказанию возникновения или не возникновения осложнений. В поисках надежной прогностической модели мы оценили три наиболее непохожих друг на друга и общепризнанно самых эффективных алгоритма классического машинного обучения: K-ближайших соседей (KNN), машины опорных векторов (SVM) и градиентный бустинг на решающий деревьях. *Результаты.* Таким образом, нами



Введение

Перитонит остается одной из актуальных проблем из-за его высокой летальности при несвоевременном или недостаточном лечении [1–5], а также возникновении послеоперационных осложнений, которые существенно осложняют реабилитацию и восстановление пациента [6–10]. Поэтому модели, позволяющие прогнозировать осложнения на основе данных, полученных при госпитализации пациента, несомненно, смогут помочь скорректировать схему лечения и повысить качество реабилитационного периода. Несмотря на достижения современной медицины, раннее выявление и профилактика осложнений остаются сложной задачей из-за индивидуальных особенностей пациента и сложного взаимодействия различных факторов риска. Для решения этих проблем мы предлагаем использовать алгоритмы машинного обучения для выявления закономерностей в большом наборе данных клинических переменных, связанных с пациентами с перитонитом.

Цель исследования

Исследование различных подходов для разработки системы прогнозирования осложнений, возникающих при перитоните, с использованием алгоритмов машинного обучения.

Материалы и методы

Были исследованы данные 1558 пациентов, которых госпитализировали с диагнозом перитонит. Среди всех пациентов представителей мужского пола — 952 пациента, женского — 606. Однако, уточним, что от распределения по полу не зависели симптомы заболевания, в связи с чем «пол пациента» не стал входить в критерии отбора параметров. Средний возраст пациентов составил 44 ± 8 лет. Исходя из комплекса результатов обследования, отобраны пациенты, соответствующие следующим критериям включения: больные с диагнозом перитонит;

были исследованы разные подходы для разработки системы прогнозирования вероятности осложнения перитонита методами искусственного интеллекта. Для рассматриваемой задачи наиболее эффективным алгоритмом оказался KNN, который был настроен с использованием перекрестной проверки и поиска гиперпараметров по сетке. *Заключение.* В качестве будущей работы необходимо продолжать мониторинг и обновление модели, учитывая изменяющиеся тенденции в данных и медицинской практике. Исследование демонстрирует потенциал использования алгоритмов машинного обучения для улучшения прогнозирования осложнений перитонита, тем самым способствуя повышению качества медицинского обслуживания и лечения пациентов.

Ключевые слова: перитонит; раннее выявление осложнений; прогнозирование осложнений; машинное обучение.

отсутствие предшествующих операций на брюшной полости, а также сопутствующих заболеваний брюшной полости, требующих оперативного вмешательства; наличие информированного согласия на проводимое оперативное вмешательство. Исходя из критериев включения были также сформулированы критерии исключения: пациенты, имеющие в анамнезе предшествующие операции, локализованные в брюшной полости, имеющие онкологические заболевания, а также пациенты с обострившимися хроническими заболеваниями. При поступлении пациентов были проведены следующие клинико-диагностические и инструментальные исследования согласно клиническим рекомендациям по острому перитониту (код по МКБ 10: K65.0) [11] (таблица 1). Разрешение на проведение исследования отражено локальным этическим комитетом (ЛЭК) Саратовского медицинского университета «Реавиз» (протокол ЛЭК номер 2 от 16.10.2023). Исследование проводили при наличии добровольных информированных согласий пациентов в соответствии с декларацией о соблюдении международных, а также Российских этических принципов и норм (выписка из протокола №19 заседания комитета по биоэтике от 26 октября 2018 года). Исследование выполнено в соответствии с требованиями Хельсинкской декларации Всемирной медицинской ассоциации (в ред. 2013 года). Для достижения поставленной цели была решена подзадача нахождения именно тех показателей, которые влияли на возникновение осложнений.

Для исследования важности признаков (данных соматического и хирургического анамнеза, данных о течении и исходах заболевания, показателей гемостатических, биохимических и коагулологических исследований, сведений о проводимой терапии основного заболевания) на возникновение осложнений были использованы методы классической статистики — попарная корреляция Пирсона [12] и методы машинного обучения — градиентный бустинг на решающих деревьях [13]. Формула для вычисления корреляции Пирсона имеет вид:

Таблица 1.

Клинико-диагностические и инструментальные исследования, выполненные при госпитализации пациентов, и их кодовое обозначение

Исследование	Код
ОАК_Гемоглобин	ОАКГМГЛ
ОАК_Гематокрит%	ОАКГМТК
ОАК_Тромбоциты	ОАКТРМБ
ОАК_Эритроциты	ОАКЭРТР
ОАК_Лейкоциты	ОАКЛЙКЦ
ОАК_СОЭ	ОАКСОЭ
ОАК_Цветовой показатель	ОАКЦВЕТ
ОАК_Ретикулоциты	ОАКРТКЛ
ОАК_Тромбокрит %	ОАКТРБК
ОАК_Эозинофилы	ОАКЭЗФ
ОАК_Базофилы	ОАКБЗФ
ОАК_Лимфоциты	ОАКЛМФЦ
ОАК_Моноциты	ОАКМНЦТ
ОАК_Средний объем эритроцитов	ОАКСРОЭР
ОАК_Палочкоядерные гранулоциты (нейтрофилы)	ОАКПЛГР
ОАК_Сегментоядерные гранулоциты (нейтрофилы)	ОАКСГГР
ОАМ_Сахар	ОАМСХР
ОАМ_Кетоновые тела	ОАМКТН
ОАМ_Общий азот мочи	ОАМОБАЗТ
ОАМ_Мочевина	ОАММЧВН
ОАМ_Мочевая кислота	ОАММЧК
ОАМ_Креатинин	ОАМКРТ
ОАМ	ОАМАММК
БХ крови_Общий белок	БХКОББ
БХ крови_С-реактивный белок	БХКСРБ
БХ крови_ЛДГ ВС	БХКЛДГ
БХ крови_Креатинин	БХККРТ
БХ крови_Мочевина	БХКМЧВН
БХ крови_АЛТ	БХКАЛТ
БХ крови_АСТ	БХКАСТ

Исследование	Код
БХ крови_Прокальцитонин	БХКПРКН
БХ крови_К	БХКК
БХ крови_Са	БХКС
БХ крови_Na	БХКН
Коагулограмма_ВСК	КЛГВСК
Коагулограмма_ПТИ	КЛГПТИ
Коагулограмма_АЧТВ	КЛГАЧТВ
посевы_из брюшной полости	ПСВБП
посевы_крови	ПСВКР
посевы_мочи	ПСВМЧ
УЗИ брюшной полости_Размеры печени 1	УЗИБРП1
УЗИ брюшной полости_Размеры печени 2	УЗИБРП2
УЗИ брюшной полости_пульс	УЗИБРПС
УЗИ брюшной полости_Узи почек 1	УЗИБПУП1
УЗИ брюшной полости_Давление	УЗИБПД
УЗИ брюшной полости_диурез	УЗИБПДЗ
УЗИ брюшной полости_объем выпота	УЗИБПОВ
УЗИ брюшной полости_спайки	УЗИБПСП
УЗИ брюшной полости_фибрин	УЗИБПФБ
Лечение_Объем инфузии	ЛЕЧОФ
Лечение_Количество инфузий	ЛЕЧКЛФ
Лечение_Препарат	ЛЕЧПР
Общее_Возраст	ЛЕЧВЗ
Лечение_Характер перитонита	ЛЕЧХП
Осложнения, возникшие на этапе лечения	ОСЛЖН
Общее_Болевой синдром	БОЛЬСН
УЗИ брюшной полости_Узи почек 2	УЗИБПУП2
Общее_Характер перитонита_диффузный	ОХПДИФУЗ
Общее_Характер перитонита_местный	ОХПМЕСТ
Общее_Характер перитонита_распространенный	ОХПРАСПР

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

где r — коэффициент корреляции, x_i — значения переменной x в выборке, \bar{x} — среднее значение переменной x , y_i — значения переменной y в выборке; \bar{y} — среднее значение переменной y .

Градиентный бустинг же на сегодняшний день фактически первый из двух подходов в машинном обучении, которые используются на практике (второй — нейросети). Бустинг на деревьях способен эффективно находить нелинейные зависимости в данных различной природы. Дерево решений — это метод машинного обучения, при котором значение целевой переменной предсказывается с помощью применения последовательности простых решающих правил. Бустинг на деревьях комбинирует деревья решений таким образом, чтобы каждое следу-

Осложнения, возникшие на этапе лечения	1
Общее_Болевой синдром	0.88
УЗИ брюшной полости_объем выпота	0.7
Общее_Характер перитонита_распространенный	0.13
Общее_Характер перитонита_диффузный	0.074
УЗИ брюшной полости_спайки	0.063
УЗИ брюшной полости_Размеры печени2	0.043
ОАК_Моноциты	0.034
ОАК_Тромбоциты	0.033
УЗИ брюшной полости_Узи почек2	0.028
БХ крови_Общий белок	0.028
БХ крови_АЛТ	0.027
ОАК_Лейкоциты	0.021
посевы_крови	0.019
БХ крови_С-реактивный белок	0.019
ОАК_Базофилы	0.015
ОАМ_Мочевина	0.014
БХ крови_Na	0.014
Коагулограмма_АЧТВ	0.013
ОАК_Гематокрит%	0.012
БХ крови_АСТ	0.012
БХ крови_K	0.011
ОАК_Ретикулоциты	0.011
посевы_мочи	0.0085
посевы_из брюшной полости	0.0085
ОАК_Лимфоциты	0.0083
ОАМ_Аммиак	0.0062
ОАК_Сегментоядерные гранулоциты (нейтрофилы)	0.0055
БХ крови_Ca	0.0052
ОАМ_Общий азот мочи	0.0037
УЗИ брюшной полости_Узи почек1	0.0013
ОАК_Палочкоядерные гранулоциты (нейтрофилы)	8e-05
УЗИ брюшной полости_Давление	-0.00021
Коагулограмма_ВСК	-0.0032
ОАМ_Мочевая кислота	-0.01
ОАК_Цветовой показатель	-0.01
ОАК_СОЭ	-0.011
ОАК_Гемоглобин	-0.012
УЗИ брюшной полости_Пульс	-0.013
ОАМ_Белок	-0.017
БХ крови_Прокальцитонин	-0.018
БХ крови_Креатинин	-0.02
УЗИ брюшной полости_Размеры печени1	-0.023
БХ крови_Мочевина	-0.024
ОАК_Эритроциты	-0.025
БХ крови_ЛДГ	-0.029
ОАМ_Креатинин	-0.03
Коагулограмма_ПТИ	-0.032
ОАК_Эозинофилы	-0.033
Общее_Возраст	-0.047
ОАК_Средний объем эритроцитов	-0.048
УЗИ брюшной полости_фибрин	-0.053
ОАК_Тромбокрит %	-0.055
Общее_Характер перитонита_местный	-0.19
УЗИ брюшной полости_диурез	-0.52

Осложнения, возникшие на этапе лечения

Рис. 1. Корреляция с целевым признаком

ющее дерево уменьшало ошибку всех предыдущих. Для оценки качества получившейся модели использовали метрики precision, recall и F1-метрику, формулы для вычисления которых имеют вид:

$$precision = \frac{TP}{TP + FP} \quad recall = \frac{TP}{TP + FN}$$

$$F1 = 2 * \frac{precision * recall}{precision + recall}$$

где TP — количество пациентов, у которых было осложнение, и модель предсказала осложнение; FP — количество пациентов, у которых не было осложнений,

но модель предсказала осложнение; FN — количество пациентов, у которых были осложнения, но модель не предсказала осложнение.

Другими словами, precision — это доля пациентов, у которых возникло осложнение из всех пациентов, которым модель предсказала осложнение. Recall (полнота) показывает, какую долю пациентов с осложнением из всех пациентов с осложнением смогла найти модель.

Построенная модель [14–17] показала хорошую предсказательную способность по предсказанию воз-

никновения или не возникновения осложнений у пациентов после операции на основе данных, собранных при поступлении пациента в приемное отделение.

Мнение, что чем больше параметров используется для обучения, тем лучше, не соответствует действительности. Неважные параметры зачастую «зашумляют» важные данные, перетягивая на себя внимание обучаемой модели. В связи с чем, в поисках надежной прогностической модели мы оценили три наиболее непохожих друг на друга и общепризнанно самых эффективных алгоритма классического машинного обучения: K-ближайших соседей (KNN), машины опорных векторов (SVM) и градиентный бустинг на решающий деревьях.

Результаты

Построение корреляционной матрицы Пирсона позволило нам наблюдать сильные корреляции между целевой переменной и несколькими признаками. Три признака показали очень высокие корреляции, причем болевой синдром был самым сильным — 0,88 (рис. 1).

Использование mutual information из Sklearn для выявления нелинейных взаимосвязей подтвердило основные характеристики, выявленные корреляционной матрицей Пирсона. Учитывая высокую корреляцию с болевым синдромом, достижение точности в 88 % стало возможным просто за счет постоянного прогнозирования осложнений при его наличии. Теперь наша цель сместилась в сторону повышения качества прогнозирования за счет использования оставшейся информации.

После подготовки нашего набора данных, разделения его на обучающие, валидационные и тестовые наборы и выполнения нормализации данных для KNN и SVM мы провели k-кратную перекрестную проверку наряду с рандомизированным поиском для оптимизации гиперпараметров.

В ходе этого процесса мы выявили в наших данных критическую особенность, связанную с тремя наиболее важными признаками: диурезом, объемом выпота и болевым синдромом [14-17] (рис. 2). Из-за их ограниченных вариаций эти факторы генерировали всего 200 уникальных комбинаций, что создавало проблему, при которой дополнительные данные, если обучать модель и делать предсказание только по этим трем признакам, представляли собой дубликаты. Эта особенность требовала полного изменения подхода к обучению.

Столкнувшись с этим препятствием, мы разработали два решения, показавших свою эффективность.

Первый подход заключался в использовании возможностей KNN, поскольку мы исходили из того, что идентичные исходные данные приведут к дублированию записей, которые при этом будут иметь разные метки классов, что делает оценку вероятности возникновения каждого набора из трёх признаков необходимой для определения распространенности (рис. 3 и рис. 4). Пример: если у 95 человек возникнут осложнения при заданном наборе трёх признаков, а у 5 других, при таком же наборе трёх признаков не возникнут осложнения, то, с точки зрения статистики, правильный ответ будет указывать на осложнения в 95 % случаев. По совпадению, KNN вычисляет вероятности точно так, как описано. Однако в данном случае большая часть «соседей» будет совпадать с входным экземпляром, находясь в пространстве признаков в одной и той же точке, расстояние до которой будет равно 0.

Во втором подходе (рис. 5), мы реализовали своеобразный feature engineering, объединив другие менее значимые признаки с нашими тремя доминирующими, применив далее нелинейный метод главных компонент (Kernel PCA) для получения новых непрерывных призна-




Рис. 2. Ограниченные вариации наиболее важных признаков

ков, которые уже можно передать бустингу без опасения присутствия дубликатов.




Рис. 3. Признаковое пространство с перекрывающимися точками




Рис. 4. Признаковое пространство с принудительно зашумленными точками

Примечание: для иллюстрационных целей понижение сделано до двухмерного пространства. Также в данном понижении не использовался самый важный признак — болевой синдром, который после понижения добавляется в качестве нового столбца к получившимся данным.

Оба подхода продемонстрировали схожую эффективность, но был выбран подход с KNN, т.к. он использовал меньше признаков и был более интерпретируемый.




Рис. 5. Признаковое пространство после понижения размерности

Используя KNN, мы достигли значения ROC-AUC (рис. 6), равного 0,98, при этом показатели precision (доля пациентов, у которых возникло осложнение из всех пациентов, которым модель предсказала осложнение) и recall (полнота; показывает, какую долю пациентов с осложнением из всех пациентов с осложнением смогла найти модель) колебались в пределах $\pm 0,95$ для положительного класса, демонстрируя незначительные колебания, обусловленные изменением разбиения набора данных на обучающие и тестовые наборы (рис. 7).




Рис. 6. ROC кривая

Classification Report:

	precision	recall	f1-score	support
0	0.95	0.98	0.97	308
1	0.97	0.91	0.94	160
accuracy			0.96	468
macro avg	0.96	0.95	0.95	468
weighted avg	0.96	0.96	0.96	468

Рис. 7. Метрики на тестовом множестве

В целом, предложенные методы успешно справились с уникальными задачами, связанными с нашим набором данных, что привело к получению точного и надежного прогнозирующего решения.

Обсуждение результатов

В настоящем исследовании представлен новый подход к прогнозированию осложнений перитонита с использованием алгоритмов машинного обучения. Была проведена тщательная работа по сбору, обработке и анализу клинических данных о пациентах с перитонитом. Были предприняты шаги по предварительной обработке и подготовке данных к моделированию.

Тремя wybranными алгоритмами машинного обучения для сравнения их производительности в прогнозировании осложнений перитонита были опорные вектора SVM, градиентный бустинг и k-ближайших соседей (KNN). После тщательного анализа и сравнения, наиболее эффективным алгоритмом оказался KNN, который был настроен с использованием перекрестной провер-

ки и поиска гиперпараметров по сетке. Результаты демонстрируют высокую степень точности и надёжности прогнозирующего решения.

Заключение

Таким образом, нами были исследованы разные подходы для разработки системы прогнозирования вероятности осложнения перитонита методами ИИ. Для рассматриваемой задачи наиболее эффективным алгоритмом оказался KNN, который был настроен с использованием перекрестной проверки и поиска гиперпараметров по сетке. Однако на данном этапе внедрение модели в клиническую практику пока преждевременно. В качестве будущей работы необходимо продолжать мониторинг и обновление модели (улучшение характеристик), учитывая изменяющиеся тенденции в данных и медицинской практике. Исследование демонстрирует потенциал использования алгоритмов машинного обучения для улучшения прогнозирования осложнений перитонита, тем самым способствуя повышению качества медицинского обслуживания и лечения пациентов.

ЛИТЕРАТУРА

1. Михайличенко В.Ю., Воронков Д.Е., Кисляков В.В., Цап А.А. Лечение тяжелых форм распространенного гнойного перитонита. Таврический медико-биологический вестник. 2022; 25 (1): 20–26.
2. Савельев В.С., Филимонов М.И., Подачин П.В., Чубченко С.В. Ошибки выбора тактики хирургического лечения распространенного перитонита. Анналы хирургии, 2008; 1: 26–32.
3. Bassetti M., Eckmann C., Giacobbe D.R., Sartelli M., Montravers P. Post-operative abdominal infections: epidemiology, operational definitions, and outcomes. Intensive Care Med, 2020; 46 (2): 163–172.
4. Piraino V. Innovations in Treatment Delivery, Risk of Peritonitis, and Patient Retention on Peritoneal Dialysis. Semin Dial, 2017; 158–163.
5. Алипов В.В., Тахмезов А.Э., Полиданов М.А., Мусаелян А.Г., Кондрашкин И.Е., Волков К.А., Алипов А.И. Улучшение результатов лечения и диагностики послеоперационных осложнений в абдоминальной хирургии с применением многофункционального устройства. Медицинская наука и образование Урала, 2023; 24 (1;113): 67–71.
6. Schmidt S., Ismail T., Puhan M.A., Soll C., Breitenstein S. Meta-analysis of surgical strategies in perforated left colonic diverticulitis with generalized peritonitis. Langenbecks Arch Surg, 2018; 403 (4): 425–433.
7. Moriwaki Y., Sugiyama M., Mochizuki Y., Yamazaki Y., Suda T., Hasegawa S., Matsuda G., Karube N., Uchida K., Yamamoto T. A pitfall of the diagnostic process of differentiating bile peritonitis from acute appendicitis. Hepatogastroenterology. 2019; 51 (56): 353–356.
8. Balanescu L., Baetu A.E., Cardoneanu A.M., Moga A.A., Bălănescu R.N. Predictors of Complicated Appendicitis with Evolution to Appendicular Peritonitis in Pediatric Patients. Medicina (Kaunas). 2022; 59 (1): 21 p.
9. Bozan M.B., Kanat B.H., Yazar F.M., Kutluer N., Azak Bozan A., Aksu A., Boran Ö.F., Güler Ö. A Diagnostic Dilemma for Acute Abdomen: Sclerosing Encapsulating Peritonitis (Abdominal Cocoon Syndrome); A Retrospective Cohort Study. Arch Iran Med. 2021; 24 (6): 447–452.
10. Gandhi K., Prasad D., Malhotra V., Agrawal D., Beniwal P., Leon Dsouza A.V. Clinicoepidemiological profile of peritonitis complicating acute peritoneal dialysis: A single-center experience. Saudi J Kidney Dis Transpl. 2017; 28 (5): 1133–1137.
11. Клинические рекомендации. Острый перитонит. Утверждены Минздравом РФ. Кодирование по Международной статистической классификации болезней и проблем, связанных со здоровьем: K65.0/K65.8/K65.9/K67/K67.0/K67.1/K67.2/K67.3. Год утверждения: 2023. Ссылка активна на 12.06.2024: <https://clck.ru/39cMnx>
12. Pearson correlation criterion. The link is active as of 12.06.2024: <https://medstatistic.ru/methods/methods8.html?ysclid=lgce2phu7s101348257>
13. CatBoost. The link is active as of 12.06.2024: <https://catboost.ai/?ysclid=lgce8l4u2w627918923>
14. Свидетельство о регистрации программы для ЭВМ № 2024612173 / 29.01.2024. Заявка от 25.12.2023. Барулина М.А., Полиданов М.А., Сухой Д.В., Волков К.А., Масляков В.В., Паршин А.В., Высоцкий Л.И. Система предсказания вероятности наступления осложнений после проведения операции больным с перитонитом. Ссылка активна на 12.06.2024: https://www.elibrary.ru/download/elibrary_60782434_97687051.PDF.
15. Свидетельство о регистрации программы для ЭВМ № 2024615898 / 13.03.2024. Заявка от 03.03.2024. Барулина М.А., Полиданов М.А., Сухой Д.В., Волков К.А., Масляков В.В., Паршин А.В., Высоцкий Л.И. Интернет-сервис для предсказания вероятности наступления послеоперационных осложнений у больных с перитонитом. Ссылка активна на 12.06.2024: <https://fips.ru/EGD/098da9a5-5ad1-45d3-9376-da9cdb9cd898>

16. Полиданов М.А., Волков К.А., Масляков В.В., Барулина М.А., Паршин А.В., Сухой Д.В., Высоцкий Л.И., Дягель А.П., Мезиров Г.Г., Марченко В.С., Кудашкин В.Н. Возможности использования алгоритмов градиентного бустинга для предсказания осложнений у пациентов с хирургическим перитонитом. *Оперативная хирургия и клиническая анатомия (Пироговский научный журнал)*, 2024; 8 (3).
17. Полиданов М.А., Сухой Д.В. Система помощи принятия врачебных решений по прогнозу возникновения осложнений при перитоните. Сборник проектов конкурса «Всероссийская научная школа «Медицина молодая»: III научно-образовательный форум, Москва, 07 декабря 2023 года. Москва: Международный фонд развития биомедицинских технологий им. В.П. Филатова, 2023; 1154–1157.

© Сухой Даниил Владимирович; Полиданов Максим Андреевич (maksim.polidanoff@yandex.ru);
Барулина Марина Александровна; Масляков Владимир Владимирович; Паршин Алексей Владимирович;
Волков Кирилл Андреевич
Журнал «Современная наука: актуальные проблемы теории и практики»