

**РОМАНЮК Т.И.,**

к.м.н., «Филипс», г. Москва, Россия, e-mail: tatsiana.ramaniuk@philips.com

**ПОЗДНЯКОВ Д.Ю.,**

«Филипс», г. Москва, Россия, e-mail: dmitriy.pozdnyakov@philips.com

**МУШЕНОК Ф.Б.,**

к.ф.-м.н, ООО «Филипс Инновационные Лаборатории Рус», г. Москва, Россия,  
e-mail: fedor.mushenok@philips.com

## ИСПОЛЬЗОВАНИЕ ВОЗМОЖНОСТЕЙ МАШИННОГО ОБУЧЕНИЯ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОТДЕЛЕНИЯХ АНЕСТЕЗИОЛОГИИ И РЕАНИМАЦИИ

DOI: 1025881/18110193\_2021\_2\_60

**Аннотация.**

*В статье описаны основные аспекты технологий машинного обучения и искусственного интеллекта. Отражены возможности их применения для отделений анестезиологии и реаниматологии. Представлен современный опыт применения цифровых систем для анализа, прогнозирования и управления данными пациента с точки зрения клинической и экономической эффективности.*

*Описана функциональность информационной системы поддержки принятия клинических решений IntelliSpace Critical Care and Anesthesia (ICCA) для отделений анестезиологии, реанимации и интенсивной терапии, основанная на управлении данными пациента, производства компании «Филипс».*

**Ключевые слова:** информационные технологии, искусственный интеллект, машинное обучение, анестезиология, реаниматология, ICCA.

**Для цитирования:** Романюк Т.И., Поздняков Д.Ю., Мушенко Ф.Б. Использование возможностей машинного обучения и искусственного интеллекта в отделениях анестезиологии и реанимации. *Врач и информационные технологии.* 2021; 2: 60-71. doi: 1025881/18110193\_2021\_2\_60.

**RAMANIUK T.I.,**

PhD, Philips LLC, Moscow, Russia, e-mail: tatsiana.ramaniuk@philips.com

**POZDNYAKOV D.YU.,**

Philips LLC, Moscow, Russia, e-mail: dmitriy.pozdnyakov@philips.com

**MUSHENOK F.B.,**

PhD, Philips Innovation Laboratories Rus, Moscow, Russia,  
e-mail: fedor.mushenok@philips.com

## USE OF THE OPPORTUNITIES OF MACHINE LEARNING AND ARTIFICIAL INTELLIGENCE IN THE INTENSIVE CARE UNIT

DOI: 1025881/18110193\_2021\_2\_60

**Abstract.**

*The article describes the main aspects of machine learning and artificial intelligence technologies, and the possibilities of their application within anaesthesiology departments and intensive care units. The modern experience of using digital systems for the analysis, forecasting and management of patient data from the point of view of clinical and economic efficiency is presented.*

*The authors present the main functionality of the information system for the support of IntelliSpace Critical Care and Anaesthesia (ICCA), and for clinical decision making for the departments of anaesthesiology and intensive care based on patient data management (Philips).*

**Keywords:** *information technology, artificial intelligence, machine learning, anesthesiology, intensive care, ICCA.*

**How to cite:** *Ramaniuk T.I., Pozdnyakov D.YU., Mushenok F.B. Use of the opportunities of machine learning and artificial intelligence in the intensive care unit. Medical doctor and information technology. 2021; 2: 60-71. (In Russ.). doi: 1025881/18110193\_2021\_2\_60.*

## ВВЕДЕНИЕ

В настоящее время важной составляющей качества оказания медицинской помощи является степень ее доступности. Что может обеспечиваться за счет широкого внедрения в учреждение здравоохранения современных информационных технологий, которые позволяют вывести диагностику и лечение на новую ступень развития. В данной работе мы рассмотрим как внедрение клинических информационных систем, на основе цифровых технологий, может помочь в решении актуальных вопросов совершенствования работы отделений анестезиологии, реанимации и интенсивной терапии (ОАРИТ).

Основной целью ОАРИТ является своевременная и эффективная коррекция и восстановление витальных функций пациентов. Для ее достижения необходимо осуществлять динамический контроль основных показателей жизнедеятельности пациентов (частота дыхания и сердечных сокращений, артериальное давление, уровень оксигенации крови, биохимические показатели крови и т.д.) с одной стороны. С другой стороны, пациенты должны получать адекватную интенсивную терапию, направленную на нормализацию гомеостаза, включающее поддержание гемодинамики, баланса жидкости и электролитов, респираторную поддержку, антибактериальную терапию и др. В настоящее время врачу ОАРИТ для принятия верного клинического решения необходимо оценивать огромный непрерывный поток данных о пациенте,

который поступает из различных информационных систем (лабораторная, рентгенологическая, общеклиническая) и с прикроватных медицинских устройств: кардио- и респираторные мониторы, аппараты искусственной вентиляции легких (ИВЛ), постоянные инфузионные системы, системы почечно-заместительной терапии и другие. Большой поток информации и обусловил разработку и внедрение информационных технологий (ИТ), позволяющих объединять, группировать, анализировать разрозненные данные и реализовывать алгоритмы для поддержки принятия клинических решений (Рис. 1).

В конце XX века началось активное внедрение ИТ в работу службы анестезиологии и реаниматологии, и с каждым днем они занимают все более уверенную позицию. Современные системы управления данными пациентов (PDMS — Patient Data Management System) прошли в своем развитии несколько этапов. PDMS первого поколения в ОАРИТ представляли собой ИТ, обеспечивающие автоматический сбор данных о пациенте с оборудования. Следующим шагом было создание механизмов обмена информацией между различными информационными системами, в том числе располагающимися вне ОАРИТ (PDMS второго поколения). В дальнейшем было реализовано создание полноценной электронной истории болезни за счет обеспечения сбора, сортировки информации от разрозненных источников и систем, и эффективного электронного документооборота — PDMS




Рисунок 1 — Схема сбора и анализа данных с прикроватного оборудования в ОАРИТ.

третьего поколения. Следующий шаг — это внедрение клинических информационных систем с возможностью новых и перспективных направлений, таких как алгоритмы машинного обучения (МО) и искусственного интеллекта (ИИ).

### ЦЕЛЬ ИССЛЕДОВАНИЯ

Проанализировать эффективность применения алгоритмов МО и ИИ для ОАРИТ на основании обзора публикаций по данной проблеме.

### МАТЕРИАЛЫ И МЕТОДЫ

Мы выполнили обзор публикаций по применению алгоритмов МО и ИИ для ОАРИТ. Были включены исследования, опубликованные в период 2001–2020 гг. Всего проанализировано 189 работ. Для подробного изучения было отобрано 16 источников, в которых наиболее подробно представлены механизмы построения математических моделей для алгоритмов МО и ИИ.

### ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МАШИННОЕ ОБУЧЕНИЕ

ИИ, МО и большие данные — технологии, кардинально изменившие нашу жизнь за последние годы, проникнув во многие сферы деятельности человека. В этом разделе мы разберем, что же такое МО, чем оно отличается от ИИ и зачем нужны большие данные.

ИИ (англ. Artificial Intelligence, AI) — научное направление, в рамках которого создаются системы, способные решать творческие задачи, раньше считавшиеся исключительно прерогативой человека. Примерами таких задач являются распознавание изображений и речи, написание текстов и музыки, выявление закономерностей. Принято выделять сильный и слабый ИИ. Сильный ИИ может приобрести способность мыслить и осознавать себя как отдельную личность, т.е. обладать «сознанием». Сама возможность создания сильного ИИ активно обсуждается среди ученых и до сих пор является спорной. Слабый ИИ не обладает «сознанием», но может решать поставленные перед ним задачи так же хорошо, как и человек, и, возможно, даже лучше.

МО (англ. machine learning, ML) — один из способов создания слабого ИИ. По сути МО возникло на стыке статистики, теории вероятности и компьютерных наук. Главная концепция МО

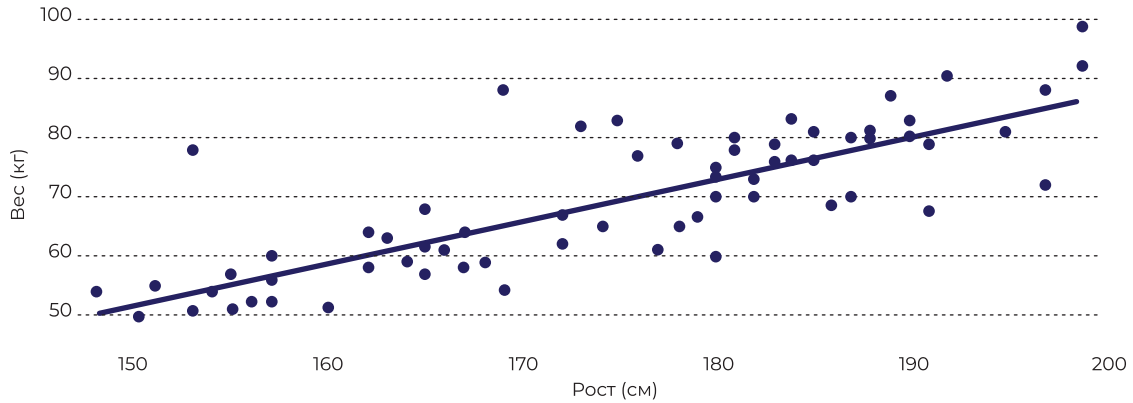
заключается в создании обучаемых параметрических моделей. Такие модели не выдают ответы, закодированные на этапе программирования, т.е. не действуют по заранее заложенному принципу вида «если..., то...». В случае МО ответы модели зависят от ее внутренних параметров. Количество параметров в одной модели может достигать десятков миллионов.

Значения этих параметров подбираются таким образом, чтобы качество даваемых ответов было наилучшим. Что считать наилучшим качеством, зависит от конкретной задачи. Процесс подбора параметров называется обучением модели. После окончания процесса обучения модели параметры фиксируются, и теперь она может быть использована для получения ответов.

Многие модели и алгоритмы, успешно применяемые в МО, изобретены еще в середине XX века и даже ранее.

Одним из примеров такой модели является линейная регрессия, т.е. пропорциональная зависимость одной величины от одной или более переменных. Проиллюстрируем это на следующем примере: мы измерим рост и массу тела у 50 взрослых здоровых мужчин. Нанесем каждое измерение на график в координатах рост—масса тела (Рис. 2). Можно заметить, что точки образуют «облако», вытянутое из нижнего левого угла в правый верхний. Теперь проведем прямую линию, которая описывается уравнением  $y=ax+b$ , так, чтобы она проходила через середину этого облака, и примерно одинаковое количество точек лежало слева и справа от этой прямой. Выбор параметров  $a$  и  $b$ , при которых прямая наилучшим образом проходит через все облако точек, и будет процессом обучения выбранной линейной модели. Теперь мы можем воспользоваться этой моделью для предсказания массы тела человека по его росту. Для этого необходимо умножить рост на коэффициент пропорциональности  $a$  и добавить смещение  $b$ .

На этом простом примере мы можем продемонстрировать несколько важных правил, которые справедливы для большинства моделей МО. Во-первых, модели зачастую дают не абсолютно точный прогноз, а лишь некоторое значение, которое может быть близко к истинному. Во-вторых, качество модели определяется качеством данных, на которых она обучена. Если использовать некачественные данные, то

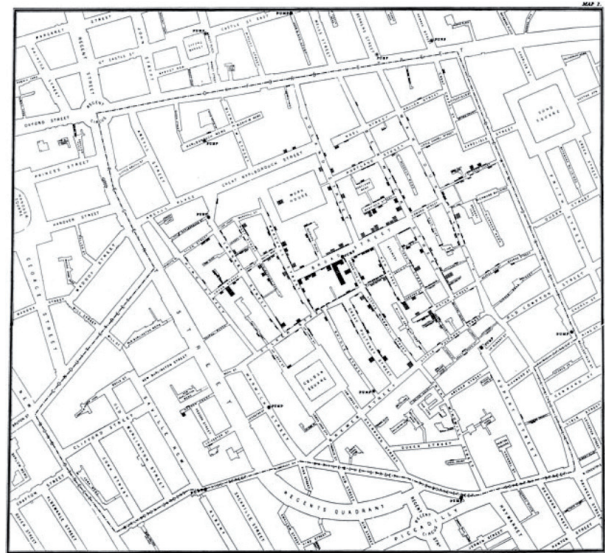


**Рисунок 2 — Измерения веса и роста людей с нормальным индексом массы тела [1]. Сплошной линией показана аппроксимация линейной зависимостью.**

модель не сможет давать хорошие предсказания. В-третьих, усложнение модели (в разумных пределах) может повысить точность результатов. Например, учет дополнительных сведений об исследуемых (например, их пол или возраст), вероятно, может повысить точность предсказаний. И последнее — каждая модель МО имеет свою область применения. Модель, хорошо предсказывающая массу тела человека, вряд ли сможет хорошо предсказывать массу тела кошек или собак.

Условно выделяют несколько разделов в МО. Представленный выше пример линейной регрессии является алгоритмом обучения с учителем (supervised learning). В таких задачах модель в процессе обучения получает как признаки объектов (в данном случае — рост), так и правильные ответы ко всем объектам (вес). Противоположная ситуация — обучение без учителя (unsupervised learning), в таком случае модель получает только признаки объектов. Примером таких задач является поиск закономерностей в данных.

Пример. Когда в 1854 г. в Лондоне вспыхнула эпидемия холеры, врач Джон Сноу, лечивший больных, нанес все известные ему случаи на карту Лондона. Оказалось, что все случаи не разбросаны случайным образом, а образуют кластеры вокруг нескольких водопроводных колонок, из которых заразившиеся брали воду. Так Джон Сноу смог установить, что причиной заражения является загрязненная вода, поступавшая в эти колонки (Рис. 3) [2].



**Рисунок 3 — Карта Джона Сноу, на которой отмечены кластеры вспышки холеры [2].**

На стыке между обучением с учителем и обучением без учителя активно развиваются несколько областей, рассматривающие промежуточные случаи: метки есть, но они могут содержать ошибки (weakly-supervised learning), или метки есть только для части данных. Как уже сказано, для обучения моделей МО необходимы данные, т.е. информация, относящаяся к решаемой задаче. Если мы хотим сделать классификатор картинок, который будет относить картинки к одной из возможных категорий, то

нам необходимы примеры таких картинок и соответствующие метки, т.е. указание, к какой из категорий относится каждая из картинок. Для обучения одной модели могут потребоваться тысячи и даже десятки тысяч примеров. Поэтому развитие МО и его повсеместное внедрение было бы невозможно без другой области — больших данных (big data). Под большими данными обычно понимают не значительный объем информации, а методы работы с большими объемами информации. Таким образом, главным в этой области является не накопление сведений об окружающем мире, а выстраивание всего цикла работы с информацией: сбор, предобработка, хранение, поиск, выявление закономерностей и т.д.

Традиционно цикл построения систем МО состоит из цикла последовательных этапов (Рис. 4). Самым первым этапом является анализ задачи, который включает в себя постановку цели, оценку ситуации, определение цели сбора данных и разработку плана. Затем следует этап анализа данных, во время которого данные собираются, описываются и анализируются. После этого наступает этап подготовки данных, на котором осуществляются необходимая подвыборка данных, их очистка и форматирование. На следующем этапе — создание модели — выбирается один или несколько алгоритмов МО, которые непосредственно обучаются на подготовленных данных. После этого следует этап оценки качества модели, на котором эксперты должны дать свое заключение — готова ли созданная модель для использования в реальных условиях? Если качество модели удовлетворяет заданным критериям, то модель передается для внедрения непосредственно в организацию с целью решения задач, для которых она создавалась. Иначе цикл повторяется вновь с этапа постановки задачи. Следует отметить, что описанный цикл в общих

чертах совпадает с этапами прикладной научно-исследовательской работы.

Качество обученных моделей оценивается с помощью так называемых метрик — численных оценок способности модели предсказывать правильные ответы на данных, которые они не видели в процессе обучения. Выбор конкретной метрики зависит от задачи и выбранного алгоритма МО. Например, в задачах бинарной классификации (т.е. предсказания одного из двух возможных вариантов ответа — да/нет) наиболее распространены следующие метрики:

- доля правильных ответов (accuracy);
- точность (precision) — доля правильно предсказанных ответов среди всех предсказанных положительных ответов. Пример: доля действительно больных пациентов среди всех пациентов, которым установлен данный диагноз;
- полнота (recall) — доля обнаруженных объектов среди всех объектов данного класса. Пример: доля пациентов с выявленным заболеванием среди всех пациентов, обследованных на наличие данного заболевания.

В реальных задачах зачастую невозможно добиться абсолютной точности предсказаний: модели с высокой точностью обладают малой полнотой, и наоборот. Поэтому в зависимости от решаемой задачи выбирается одна метрика, которая и будет оптимизироваться, либо идут на компромисс и выбирают их баланс. К примеру, в случае скрининговых обследований на наличие туберкулеза стоит максимизировать полноту, чтобы обнаружить как можно больше людей, страдающих этим заболеванием.

Хотя на первый взгляд МО и большие данные могут показаться загадочными, на самом деле они тесно связаны с традиционными статистическими моделями, которые узнаваемы для большинства клиницистов. Мы надеемся, что




Рисунок 4 — Диаграмма процесса создания систем машинного обучения [3].

выяснение этих связей позволит демистифицировать эти методы и обеспечит набор разумных ожиданий относительно роли машинного обучения и больших данных в здравоохранении. Имеется ряд сообщений о разработке алгоритмов МО и эффективном внедрении их в клиническую практику ОАРИТ, направленных на прогнозирование необходимости госпитализации, 30- и 90-дневной выживаемости, вариантов медикаментозной терапии, длительности аппаратной вентиляции, возможных сроков перевода из отделений интенсивной терапии, летальности при различных патологиях и т.п. [3–6]. Каждый из них дает возможность клиническим специалистам использовать современный инструмент МО для повышения качества проводимой терапии, что влияет в первую очередь на выживаемость пациентов, длительность пребывания в ОАРИТ и стационаре и, что немаловажно, на стоимость лечения. Кроме того, демонстрируется возможность сбора и анализа большого количества данных с созданием условий в помощи принятия клинических решений, создания статистических отчетов и выявления закономерностей.

Ниже мы рассмотрим несколько наиболее востребованных направлений применения систем принятия решений и больших данных в ОАРИТ.

### МО И ИИ В ОАРИТ

#### Возможности для прогнозирования развития сепсиса.

Одной из значимых проблем ОАРИТ является развитие системной инфекции (сепсис), так как ее возникновение не только ухудшает течение основного заболевания, но и служит потенциальным предиктором летального исхода пациента. Каждую минуту от сепсиса в мире погибают не менее 14 человек, а ежегодно — больше людей, чем от рака предстательной железы, молочной железы и ВИЧ вместе взятых, что выводит сепсис на лидирующее место среди всех причин смерти взрослого населения [7]. По данным Всемирной организации здравоохранения за 2018 г., общемировое эпидемиологическое бремя сепсиса не поддается точной оценке. Согласно расчетам, он ежегодно развивается более чем у 30 млн человек и, возможно, уносит жизни около 6 млн [7]. Каждый год сепсис диагностируется у 3 млн

новорожденных и 1,2 млн детей [8]. Несмотря на отсутствие официальных достоверных единых статистических данных, к сожалению, проблема высокой летальности при сепсисе весьма актуальна и для России. Немаловажно и то, что среднее пребывание в стационаре при сепсисе в 2 раза дороже, чем при других состояниях, а средняя заболеваемость тяжелым сепсисом увеличивается примерно на 13% в год [9]. Адекватная диагностика и своевременно начатое эффективное лечение снижают связанные с лечением расходы и смертность. Несмотря на очевидные преимущества, раннее и точное выявление сепсиса остается сложной клинической проблемой [9]. Развитие технологии МО и использования больших данных в ОАРИТ имеет свои перспективы для решения этой задачи.

Так, в работе Q. Мао и соавт. (2018), выполненной в клиниках Калифорнии и Вашингтона (США), получены статистически значимые данные о прогнозировании развития сепсиса. Работа основана на построении алгоритма МО InSight с выборкой данных из медицинской информационной системы, включающей 90353 пациентов. Алгоритм основан на ретроспективных данных и применен в дальнейшем к проспективному анализу. В основе модели лежит анализ основных клинических данных пациента: уровень систолического артериального давления, уровень диастолического артериального давления, частота сердечных сокращений, частота дыхания, насыщение крови кислородом и температура тела, а оценка риска формируется на основе алгоритмического дерева решений. Проведено сравнение прогнозов разработанного алгоритма InSight и «золотого стандарта» с тремя распространенными клиническими системами оценки ухудшения состояния пациентов: MEWS (Modified Early Warning Score), SIRS (Systemic Inflammatory Response Syndrome), SOFA (Sequential Organ Failure Assessment). InSight превзошел эти общепринятые подходы оценки для скрининга сепсиса, тяжелого сепсиса и септического шока. Разработанная модель МО прогнозирует развитие сепсиса за 4 ч до его начала с высоким уровнем чувствительности 0,80 и достигает специфичности 0,95, 0,84 — для тяжелого сепсиса и 0,99 — для обнаружения септического шока в отличие от стандартных схем прогнозирования (0,75, 0,72 и 0,84 соответственно).

Заблаговременное выявление пациентов, склонных к тяжелому сепсису, может расширить окно для своевременного клинического вмешательства. Высокая эффективность алгоритма в академических и муниципальных больницах, включенных в это исследование, предполагает потенциальную высокую эффективность его и в других клинических условиях [10].

В работе E. Rivers и соавт. (2001) также представлен алгоритм прогнозирования развития сепсиса, получивший название AISE (Artificial Intelligence Sepsis Expert). В его основе лежит адаптированный метод анализа выживаемости, принимающий на вход 65 различных параметров с различной временной изменчивостью — от статичных параметров (пол, возраст пациента) до временных рядов высокого разрешения (с временным шагом 2 с). Разработанный алгоритм показал высокую точность предсказания развития сепсиса во временном интервале до 12 ч (площадь под кривой ROC составляет 0,83—0,85). Наглядно продемонстрировано, что имеется высокая корреляция между припоздавшим началом эффективной антимикробной терапии и внутрибольничной смертностью: при задержке назначения препаратов на 1 час скорректированное отношение шансов (ОШ) составило 1,119, 95% доверительный интервал (ДИ) 1,103—1,136,  $p = 0,001$ . Каждый час задержки течение последующих 6 ч в назначении антимикробных препаратов в связан со средним снижением выживаемости на 7,6%. Ко 2-му часу внутрибольничная летальность статистически значимо повышалась по сравнению с получением терапии в течение 1-го часа (ОШ 1,67; 95% ДИ 1,12—2,48). Таким образом, продемонстрировано, что интервал времени до начала эффективной антимикробной терапии являлся значимым предиктором исхода [9].

#### **Возможности для прогнозирования неблагоприятных клинических инцидентов.**

Для большинства пациентов, находящихся на лечении в ОАРИТ, не столько основное заболевание может привести к неблагоприятному исходу, сколько развитие возможных осложнений. Зачастую малозаметные их признаки возникают за несколько часов до непосредственного развития жизнеугрожающих состояний, что не всегда может быть диагностировано клинически. В

таких ситуациях многие осложнения могут быть распознаны по монотонному ухудшению инструментальных либо лабораторных показателей на протяжении длительного промежутка времени. Алгоритмы МО, которые в режиме реального времени анализируют данные, поступающие от прикроватного оборудования, могут быть настоящей панацеей для заблаговременного прогнозирования развития неблагоприятных инцидентов, создания возможности адекватной коррекции состояния пациента с целью его стабилизации и исключения риска дальнейшего ухудшения.

В исследовании, проведенном в междисциплинарном отделении интенсивной терапии на 60 коек Бернской университетской клиники (Швейцария), принимающем >6500 пациентов в год, разработан основанный на методах МО алгоритм, предупреждающий врачей об угрозе развития недостаточности кровообращения за 8 ч до предполагаемого неблагоприятного инцидента. Обработка данных, подготовка моделей и анализ проводились на кафедрах компьютерных наук, а также биосистемной науки и техники в ETH Zürich (Швейцария).

Цель исследования состояла в том, чтобы оценить гемодинамику в клиническом контексте, сосредоточив внимание на доле случаев недостаточности кровообращения, которые система способна обнаружить, и частоте ложных тревог. Точность модели определена как доля сигналов тревоги, которые правильно предсказывают наступление события (период недостаточности кровообращения) в течение последующих 8 ч. Для проспективной регистрации информации о состоянии здоровья пациента, измерения параметров функций органов, результатов лабораторных анализов и параметров лечения от поступления в ОАРИТ до выписки использовали данные 9040 пациентов в возрасте от 16 до 100 лет (240 пациентов в год), из них более 1000 пациентов тестовой системы circEWS GMB MIMIC, включенных в исследование после внедрения электронной системы управления данными пациентов (PDMS; GE Centricity Critical Care, General Electrics, Хельсинки, Финляндия) в период с 2008 г. по август 2016 г. Для оценки эффективности прогнозирования использовали регистрацию клинических показателей состояния кровообращения. Из 175 получаемых от



пациента параметров определены 17 основных, 3 опорных: уровень лактата (в артериальной и венозной крови), уровень среднего артериального давления (АДср) и применение вазоактивных/инотропных препаратов. Использовали 6 основных статистических характеристик пациента: возраст, показатель хирургической госпитализации, показатель экстренной госпитализации, тяжесть состояния по шкале APACHE II, рост и пол, которые были объединены во временную сетку выборки.

При использовании МО для разработки системы раннего предупреждения о недостаточности кровообращения на основе базы данных показателей интенсивной терапии высокого разрешения установили, что автоматическая система (circEWS GMB MIMIC) предсказывала 90,0% случаев развития недостаточности кровообращения (распространенность 3,1%), при этом наступление 81,8% случаев выявлялось более чем за 2 ч до начала инцидента [4].

В своем исследовании А. Меуер и соавт. разработали и протестировали алгоритмы МО для предсказания трех наиболее характерных типов осложнений, возникающих после операций на открытом сердце: постоперационного кровотечения с необходимостью оперативной ревизии, почечной недостаточности с необходимостью заместительной почечной терапии, летального исхода. В качестве базовой модели использована рекуррентная нейронная сеть, обученная на данных 47559 пациентов. Данные включали общие сведения о пациенте (4 признака), информацию о проведенной операции (9), витальные функции (11), газовый состав артериальной крови (9), лабораторные анализы (17), жидкостный баланс (2). Качество построенных моделей сравнивалось по базовым метрикам (точность, чувствительность, полнота и др.) с тремя основными шкалами, используемыми для оценки состояния пациентов:

- клиническое правило послеоперационного кровотечения (Clinical rule for postoperative bleeding, Vojar) для прогнозирования риска кровотечения;
- упрощенная оценка острого физиологического состояния (Simplified Acute Physiology Score II, SAPS II) — для летальности;
- заболевание почек: улучшение глобальных результатов (Kidney Disease: Improving Global

Outcomes, KDIGO) — для почечной недостаточности.

Во всех трех случаях качество прогнозов, даваемых алгоритмами МО, оказалось значительно выше. Так, доля правильных ответов возросла не менее чем на 17% [11].

Другое исследование С. Subbe и соавт., проведенное в университетской клинике Великобритании, было направлено на изучение и возможность предотвращения «запоздалой реакции на клиническое ухудшение» состояния пациентов в ОАРИТ при внедрении методов электронной автоматизированной консультативной системы (ЭАКС) мониторинга и оповещения об изменении жизненно важных показателей пациента. В результате обследованы 2139 пациентов до (ретроспективно контрольная группа) и 2263 — после внедрения. При применении ЭАКС количество уведомлений о «запоздалой реакции на клиническое ухудшение» увеличилось с 405 до 524 ( $p = 0,001$ ), причем больше уведомлений вызвано инфузионной нагрузкой, применением бронходилататоров и антибактериальных препаратов. Следует отметить, что, несмотря на увеличение числа пациентов с приказами «не пытайтесь реанимировать» (с 99 до 135;  $p = 0,047$ ), количество летальных исходов снизилось со 173 до 147 ( $p = 0,042$ ), а остановка сердечной деятельности уменьшилась с 14 до 2 случаев ( $p = 0,002$ ). В итоге, тяжесть заболевания у пациентов, поступивших в ОАРИТ, снижена (средняя оценка острого физиологического и хронического состояния здоровья II балла: 26 (SD 9) по сравнению с 18 (SD 8)), как и летальность (от 45% до 24%;  $p = 0,04$ ) [12].

Такое раннее прогнозирование неблагоприятных инцидентов позволяет существенно улучшить качество оказания помощи и снизить расходы на ее проведение.

### **Возможности МО для формирования адекватного лабораторного контроля.**

Значимым звеном в динамическом наблюдении за пациентами в ОАРИТ является достаточный и своевременный лабораторный контроль. При этом возникает необходимость соблюдать баланс между ожидаемой пользой от определения того или иного лабораторного показателя для принятия клинического решения

по данному тесту и затратами или риском, которые он представляет для пациента и организации.

МО также может успешно использоваться для оптимизации процесса лабораторного мониторинга. Об этом свидетельствуют данные исследования, проведенного в Принстонском университете, США (Department of Electrical Engineering, Department of Computer Science, Center for Statistics and Machine Learning, Princeton University). Основой исследования являлось извлечение интересующей когорты лабораторных тестов из базы данных MIMIC III [13], которая включала в себя деидентифицированные данные о критической помощи при более чем 58000 госпитализаций. Из этой базы данных сперва отбирали взрослых пациентов с, по крайней мере, одним зарегистрированным измерением для каждого из 20 жизненно важных показателей и лабораторных тестов, обычно рутинно заказываемых и проверяемых клиницистами (например, результаты в биохимическом анализе крови или кислотно-основного состояния крови). Далее данные о пациентах структурировали по продолжительности пребывания в ОАРИТ, учитывая только тех, кто находится в отделении более 1 и менее 20 дней, и, таким образом, сформировали основную группу из 6060 наблюдений. Из 20 оцениваемых физиологических признаков определили 8, которые более точно предсказывали начало тяжелого сепсиса, септического шока или острого почечного повреждения, оценку SIRS (синдрома системного воспалительного ответа) и SOFA (последовательная оценка органной недостаточности) [8; 14]: частота дыхания в 1 мин, частота сердечных сокращений в 1 мин, АДср, температура тела, уровень креатинина, мочевины и лактата в сыворотке крови, содержание лейкоцитов в крови. Из этих 8 признаков первые 3 являлись жизненно-важными показателями, измеряемыми с помощью систем прикроватного мониторинга, которые регистрировались ежечасно; последние 4 являлись лабораторными, требующими инвазивного вмешательства, и обычно измерялись 2—3 раза в сутки. С учетом того, что частота назначений их варьировала в разных лабораториях и ОАРИТ, был разработан алгоритм, основанный на структуре многовыходового гауссовского процесса [8] для

получения ежечасных прогнозов состояния пациента с количественной неопределенностью по 17 из 20 клинических признаков (всего проанализировано более 800 000 шагов). Для прогнозирования были определены параметры, входящие в шкалу оценки тяжести состояния SOFA. Это мотивировалось тем, что на практике сепсис чаще распознается по сопутствующей органной недостаточности, чем по непосредственному выявлению самой инфекции [15]. Прирост по SOFA 2 баллов и более считался критическим показателем для развития сепсиса [4] и являлся предиктором для лабораторного контроля. В разработанной математической модели учитывались не только рассчитанная тяжесть состояния и его динамика в зависимости от изменения проводимой терапии, но и условная стоимость лабораторного теста. После того, как было внедрено МО в тестовой группе, были сформированы следующие рекомендации по лабораторному контролю: основное внимание необходимо акцентировать на данных, получаемых с прикроватного оборудования (частота дыхания, частота сердечных сокращений, уровень АДср), так как их изменения позволяют раньше предопределить развитие критических инцидентов (показания к диализу, необходимость перевода на ИВЛ); лабораторный контроль основных показателей следует проводить не чаще 1 раза в 24-часовой интервал, если нет прироста по SOFA >2 баллов в течение 1 ч, и только в случае увеличения оценки по SOFA >2 баллов в течение 1 ч необходимы контроль уровня лактата в сыворотке крови и дальнейшая расширенная лабораторная диагностика [16]. Тем самым показана необоснованность рутинного лабораторного контроля у всех пациентов в ОАРИТ 3—4 раза в сутки, что снижает не только затраты на проводимое лечение, но и высокую информационную нагрузку на клинициста. Например, в случае рекомендации о назначении определения уровня лейкоцитов крови в тестовом наборе достигнуто общее снижение такого назначения на 44% по сравнению с контрольной группой, при назначении анализа для определения уровня лактата крови — на 27%.

Все это позволяет оптимизировать подходы к диагностическим мероприятиям в интенсивной терапии.

### Система поддержки принятия клинических решений.

С учетом мирового опыта эффективного применения алгоритмов ИТ, МО и ИИ для работы с данными пациента в ОАРИТ, весьма перспективным является их внедрение и в клиниках России. В настоящее время среди представленных в России технологий, которые относятся к PDMS для анестезиологии и реаниматологии на основе сбора, обработки и анализа данных, такая возможность имеется у системы IntelliSpace Critical Care and Anesthesia производства компании «Филипс». Данная система разработана специально для ведения документации, построения медицинской карты и поддержки принятия клинических решений в ОАРИТ и имеет следующую функциональность:

- позволяет автоматизировать и структурировать информационные потоки, которые имеются в анестезиологических и реанимационных отделениях, за счет оцифровки медицинских данных пациента (больших данных), получаемых с практически любого прикроватного оборудования — носителя информации о пациенте, такого как наркозно-дыхательные аппараты, гемодинамические мониторы, аппараты ИВЛ и капнографы, инфузионные стойки и прочее, что полностью исключает необходимость «ручной регистрации» данных в документах;
- может обеспечивать тесное прямое взаимодействие с другими медицинскими информационными системами для обмена данными: получение результатов лабораторных и инструментальных исследований, заключений специалистов и др.;
- электронный документооборот, специализированный для ОАРИТ: кроме дневников наблюдения, протоколов течения анестезии и манипуляций, есть электронная карта интенсивной терапии, карты респираторного и гемодинамического мониторинга, карта течения анестезии, карта метаболического баланса, в которых автоматически непрерывно фиксируются все данные о пациенте, включая назначения, результаты исследований и прочее;
- имеется полная автоматизация клинических шкал для оценки степени тяжести состояния пациента: шкала комы Глазго, qSOFA, SOFA,

APACHE II, MPM II, SAPS II, CAM-ICU, Ramsay, Aldrete, ASA и др.;

- встроена система поддержки принятия клинических решений, основанная на анализе данных пациента: ведение пациентов с подозрением на развитие или подтвержденным сепсисом, профилактика тромбоза глубоких вен, профилактика возникновения вентилятор-ассоциированной пневмонии, контроль и коррекция уровня гликемии, профилактика развития катетер-ассоциированной инфекции кровотока; с возможностью формирования при необходимости уникальных настроек для определенной категории пациентов.

Таким образом, создается полноценная электронная история болезни пациента, содержащая высокоточные данные, что позволяет использовать технологию работы с большими данными, проводить комплексный анализ и прогнозировать изменения в состоянии пациента. Система обеспечивает врачам возможность своевременно принимать эффективные клинические решения, опираясь на несколько сотен медицинских параметров (с оборудования, лабораторной системы, информации о назначениях препаратов, об аллергиях, диагнозах, прогнозах и прочее).

Предоставляя широкий функционал врачу анестезиологу-реаниматологу, цифровизация ОАРИТ может обеспечивать и административные нужды клиники: полностью прозрачное, оцифрованное сопровождение пациента, контролируемое по разным параметрам (длительность, наполняемость, стоимость) с возможностью оптимизации времени/качества/затрат, что применимо к каждому конкретному пациенту, патологии, отделению и клинике в целом.

Для научных целей доступны оцифрованные мультиданные с минимальной погрешностью. Все это положительно влияет на развитие анестезиологии и реаниматологии в целом и на повышение качества лечения каждого пациента в частности.

### Выводы

Таким образом, современные ИТ, включающие в себя применение алгоритмов МО и ИИ, являются высокоэффективными технологиями позволяющими оптимизировать работу

специалистов за счет автоматизации рутинно выполняемых действий и повысить качество оказания медицинской помощи в ОАРИТ. Они обеспечивают безопасность пациентов,

благодаря структурированию и анализу данных, прогнозированию состояния, логистике перемещения, и позволяют моделировать процесс диагностики и терапии.

#### ЛИТЕРАТУРА/REFERENCES

1. 500 Person Gender-Height-Weight-Body Mass Index. Available at: <https://www.kaggle.com/yversever/500-person-gender-height-weight-bodymassindex>.
2. Snow-cholera-map-1.jpg. Available at: <https://en.wikipedia.org/wiki/File:Snow-cholera-map-1.jpg>.
3. Shearer C. The CRISP-DM model: the new blueprint for data mining. *Journal of Data Warehousing*. 2000; 5: 13-22.
4. Lizotte DJ, Laber EB. Multi-objective Markov decision processes for data-driven decision support. *Journal of Machine Learning Research: JMLR*. 2016; 17: 211.
5. Ren O, Johnson A, Lehman E, Komorowski M, Aboab J, Fengyi Tang, Shahn Z, Sow D, Mark R, Li-Wei Lehman. Predicting and Understanding Unexpected Respiratory Decompensation in Critical Care Using Sparse and Heterogeneous Clinical Data. *IEEE International Conference on Healthcare Informatics (ICHI)*. New York; 2018; 144-151. doi: 10.1109/ICHI.2018.00024.
6. Singer M, Deutschman CS, Seymour CW, Shankar-Hari M, Annane D, Bauer M, Bellomo R, Bernard GR, Chiche JD, Coopersmith CM, Hotchkiss RS, Levy MM, Marshall JC, Martin GS, Opal SM, Rubenfeld GD, van der Poll T, Vincent JL, Angus DC. The third international consensus definitions for sepsis and septic shock (sepsis-3). *JAMA*. 2016; 315(8): 801-810. doi: 10.1001/jama.2016.0287.
7. Fleischmann-Struzek C, Goldfarb DM, Schlattmann P, Schlapbach LJ, Reinhart K, Kissoon N. The global burden of pediatric and neonatal sepsis: a systematic review. *The Lancet. Respiratory Medicine*. 2018; 6(3): 223-230. doi: 10.1016/S2213-2600(18)30063-8.
8. Cheng L-F, Darnell G, Chivers C, Draugelis M, Li K, Engelhardt B. Sparse multi-output Gaussian processes for medical time series prediction. *BMC Medical Informatics and Decision Making*. 2020; 20(1): 152. doi: 10.1186/s12911-020-1069-4.
9. Rivers E, Nguyen B, Havstad S, Ressler J, Muzzin A, Knoblich B, Peterson E, Tomlanovich M; Early Goal-Directed Therapy Collaborative Group. Early goal-directed therapy in the treatment of severe sepsis and septic shock. *The New England Journal of Medicine*. 2001; 345(19): 1368-1377. doi: 10.1056/NEJMoa010307.
10. Mao Q, Jay M, Hoffman JL, Calvert J, Barton C, Shimabukuro D, Shieh L, Chettipally U, Fletcher G, Kerem Y, Zhou Y, Das R. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU. *BMJ Open*. 2018; 8(1): e017833. doi: 10.1136/bmjopen-2017-017833.
11. Meyer A, Zverinski D, Pfahringer B, Kempfert J, Kuehne T, Sündermann SH, Stamm C, Hofmann T, Falk V, Eickhoff C. Machine learning for real-time prediction of complications in critical care: a retrospective study. *The Lancet. Respiratory Medicine*. 2018; 6(12): 905-914. doi: 10.1016/S2213-2600(18)30300-X.
12. Subbe CP, Duller B, Bellomo R. Effect of an automated notification system for deteriorating ward patients on clinical outcomes. *Critical Care*. 2017; 21(1): 52. doi: 10.1186/s13054-017-1635-z.
13. Johnson AE, Pollard T. J., Shen L, Lehman L-W. H, Feng M, Ghassemi M, Moody B, Szolovits P, Celi LA, Mark RG. MIMIC-III, a freely accessible critical care database. *Scientific Data*. 2016; 3: 160035. doi: 10.1038/sdata.2016.35.
14. Vincent JL, Martin GS, Levy MM. QSOFA does not replace SIRS in the definition of sepsis. *Critical Care*. 2016; 20(1): 210. doi: 10.1186/s13054-016-1389-z.
15. De Backer D, Donadello K, Sakr Y, Ospina-Tascon G, Salgado D, Scolletta S, Vincent JL. Microcirculatory alterations in patients with severe sepsis: impact of time of assessment and relationship with outcome. *Critical Care Medicine*. 2013; 41(3): 791-799. doi: 10.1097/CCM.0b013e3182742e8b.
16. Cheng L-F, Prasad N, Engelhardt BE. An Optimal Policy for Patient Laboratory Tests in Intensive Care Units. *Pacific Symposium on Biocomputing*. 2019; 24: 320-331.