

**А.В. ГУСЕВ,**

к.т.н., член Экспертного совета Министерства здравоохранения РФ по вопросам использования информационно-коммуникационных технологий в системе здравоохранения, эксперт ООО «Комплексные медицинские информационные системы» (К-МИС), г. Петрозаводск, Россия, e-mail: agusev@kmis.ru

Д.В. ГАВРИЛОВ,

эксперт по медицине, ООО «К-Скай», г. Петрозаводск, Россия, e-mail: dgavrilov@webiomed.ai

И.Н. КОРСАКОВ,

к.ф.м.н., член рабочей группы «Электронная кардиология» Европейского общества кардиологов, эксперт в области использования методов ИИ в медицине, ООО «К-Скай», г. Петрозаводск, Россия, e-mail: igor.korsa@gmail.com

Л.М. СЕРОВА,

к.т.н., эксперт в области IT и математическом моделировании социальных процессов, ООО «К-Скай», г. Петрозаводск, Россия, e-mail: lserova@webiomed.ai

Р.Э. НОВИЦКИЙ,

директор ООО «Комплексные медицинские информационные системы» (К-МИС), г. Петрозаводск, Россия, e-mail: roman@kmis.ru

Т.Ю. КУЗНЕЦОВА,

д.м.н., доцент, зав. кафедрой факультетской терапии, фтизиатрии, инфекционных болезней и эпидемиологии, ФГБОУ ВО ПетрГУ, г. Петрозаводск, Россия, e-mail: eme@sampro.ru

ПЕРСПЕКТИВЫ ИСПОЛЬЗОВАНИЯ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРЕДСКАЗАНИЯ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ

УДК 002.53

Гусев А.В.¹, Гаврилов Д.В.², Корсаков И.Н.², Серова Л.М.², Новицкий Р.Э.¹, Кузнецова Т.Ю.³ *Перспективы использования методов машинного обучения для предсказания сердечно-сосудистых заболеваний* (1 «Комплексные медицинские информационные системы», г. Петрозаводск, Россия; 2 «К-Скай», г. Петрозаводск, Россия; 3 ФГБОУ ВО ПетрГУ, г. Петрозаводск, Россия)

Аннотация. Заболеваемость и смертность от сердечно-сосудистых заболеваний (ССЗ) остается лидирующей на протяжении последних десятилетий в всем мире. Методы первичной профилактики, основанные на управлении факторами сердечно-сосудистого риска, являются наиболее эффективными для снижения бремени ССЗ. В профилактической медицине для управления рисками ССЗ используются рискометры – шкалы, полученные в результате длительных проспективных исследований. Но практическое применение разработанных шкал показало ограничения в точности прогнозирования. Машинное обучение дает возможность повысить точность прогнозирования сердечно-сосудистого риска за счет нелинейных взаимосвязей их более глубокой настройки между факторами риска и результатами заболеваний. Используя данные 2236 пациентов, нами была обучена модель по признакам, используемым в построении фрамингемской шкалы. Мы сравнили полученную модель и Фрамингемскую шкалу на точность прогноза сердечно-сосудистого события. Так, по ROC анализу для Фрамингемской шкалы показатели следующие: точность Accuracy: 70,0%, качество AUC: 0.59. При этом для модели, полученной с использованием машинного обучения, аналогичные показатели составили: Accuracy: 78,8%, AUC: 0.84. Таким образом, использование алгоритмов машинного обучения, включая алгоритмы глубокого обучения, могут значительно повысить точность прогнозирования сердечно-сосудистых рисков обученных моделей.

Ключевые слова: здравоохранение, медицина, сердечно-сосудистые заболевания, факторы риска, оценка рисков развития заболеваний, машинное обучение, искусственный интеллект.

UDC 002.53

Gusev A.V.¹, Gavrilov D.V.², Korsakov I.N.², Serova L.M.², Novitsky R.E.¹, Kuznetsova T.Yu.³ *Prospects for the use of machine learning methods for predicting cardiovascular disease* (1 «Complex Medical Information Systems», Petrozavodsk, Russia, 2 «K-Skai», Petrozavodsk, Russia, 3 Petrozavodsk State University, Petrozavodsk, Russia)

Abstract. Morbidity and mortality from cardiovascular diseases (CVD) has remained the leading rate in recent decades worldwide. Primary prevention methods based on the management of cardiovascular risk factors are most effective in reducing the burden of CVD. In preventive medicine for risk management of CVD use the riskometers – scales that was obtained as a result of long prospective studies. But the practical application of the developing scales has showed the limitations in the forecast accuracy.

Machine learning makes it possible to improve the accuracy of cardiovascular risk prediction due to nonlinear relationships of their deeper adjustment between risk factors and disease outcomes.

2236 patients' data were used. We trained the model on the features used in the Framingham scale construction. We compared the resulting model and the Framingham scale for the accuracy of the cardiovascular event prediction. Thus, according to the ROC analysis for the Framingham scale, the indicators are as follows: precision Accuracy: 70.0%, the AUC: 0.59. At the same time for the model obtained using machine learning similar indicators were: Accuracy: 78.8%, AUC: 0.84. Thus, the use of machine learning algorithms including deep learning algorithms can significantly improve the accuracy of cardiovascular risk prediction of trained models.

Keywords: healthcare, medicine, cardiovascular diseases, CVD, risk factors, determining the risk of developing cardiovascular diseases, machine learning, ML, artificial intelligence, AI.



АКТУАЛЬНОСТЬ

Сердечно-сосудистые заболевания (ССЗ) продолжают оставаться наиболее актуальной проблемой здравоохранения большинства стран мира, в том числе и в Российской Федерации. Согласно данным Всемирной организации здравоохранения, ежегодно в мире от сердечно-сосудистых заболеваний (ССЗ) погибает более 17 млн. человек, из них от ишемической болезни сердца (ИБС) – более 7 млн. [1, 2].

В течение последних 30–40 лет было достигнуто многократное снижение заболеваемости и смертности от ССЗ, в том числе от ИБС. Эта положительная тенденция связана не только с высоким уровнем лечения ИБС, но и в первую очередь с проведением мероприятий первичной профилактики [3].

Научной основой профилактики ССЗ является концепция факторов риска (ФР), которые были выявлены в эпидемиологических исследованиях. И с 1961 г., после опубликования первых результатов Фрамингемского исследования (ФИ), началась эра изучения ФР, а ИБС названа в качестве ведущей причины смерти в США [4]. В этой работе авторы впервые показали, что риск развития ИБС связан с артериальной гипертонией (АГ), повышенным уровнем общего холестерина (ОХС) и электрокардиографическими признаками гипертрофии левого желудочка. В последующем были разработаны другие шкалы сердечно-сосудистого риска, основной из которых в Европе и у нас в стране стала шкала SCORE [5], получившая общемировое признание и повсеместное использование.

Одним из важнейших достижений эпидемиологии неинфекционных заболеваний в настоящее время следует признать переход от оценки отдельных ФР к оценке общего, или суммарного, риска. Иными словами – к созданию прогностических моделей. Результаты, полученные в ФИ, позволили разработать методику многомерного моделирования риска развития ССЗ и их осложнений. С помощью метода логистической регрессии уже в 1976 г. была создана первая система прогнозирования суммарного риска развития ИБС. Определение общего риска развития ИБС в ранних крупных эпидемиологических исследованиях вызвало интерес к возможности определения индивидуального риска развития ИБС у пациентов с целью предупреждения этого заболевания [6].

Прогнозирование риска ССЗ становится все более важным в принятии клинических решений

с момента их введения на международном уровне в последние руководящие принципы [7].

В то же время прогнозирование риска ИБС на основании анализа традиционных факторов риска сопряжено с рядом проблем. Во ФИ при наблюдении в течение 26 лет выявлено значительное совпадение групп лиц без установленной ИБС и людей, у которых развивается ИБС. По уровню традиционных ФР, было отмечено совпадение уровня ОХС (3,9–7,8 ммоль/л) между группами [8]. Отмечено значительное совпадение групп больных ИБС и здоровых мужчин по уровню традиционных ФР (ОХС, ХС ЛПНП, курению, АГ, ИМТ) и достоверное различие по ХС ЛПВП, ТГ и отношению ХС ЛПНП/ХС ЛПВП. В проспективном исследовании NPHS2 сравнивалась предсказательная способность алгоритмов для оценки сердечно-сосудистого риска Framingham и Procam [9, 10]. Оба эти алгоритма имели ложноотрицательный результат >85%.

Низкая точность предсказания сердечно-сосудистых событий имеет ряд причин. Во-первых, оценка суммарного риска должна быть адаптирована в зависимости от национальных и региональных особенностей. Во-вторых, с учетом дизайна входящих в разработку шкал исследований, в них часто не учтены существенные для наступления сердечно-сосудистого события клинические состояния (сахарный диабет I и II типа, хроническая болезнь почек или очень высокие уровни отдельных факторов риска). В-третьих, данные, которые были использованы для составления шкал, были получены 30–50 лет назад и могут не соответствовать современным реалиям. В-четвертых, математические методы расчета рисков также имеют погрешности и ограничения по применимости. Таким образом, мы можем уверенно говорить о проблеме недостаточной точности результатов расчета сердечно-сосудистого риска на основании общепринятых шкал.

Машинное обучение дает хорошие возможности решить эту проблему и существенно повысить точность прогнозирования сердечно-сосудистых заболеваний и их осложнений в сравнении с использованием существующих методик, за счет учета нелинейных взаимосвязей их точной настройки между факторами сердечно-сосудистого риска и проявлением заболеваний. В последнее время расчет число исследований и разработок в этой области [11, 12, 13, 14, 17].



ЦЕЛЬ И ДИЗАЙН ИССЛЕДОВАНИЯ

Целью нашего исследования было повышение точности предсказания рисков развития сердечно-сосудистых заболеваний на основе Фрамингемской шкалы путем применения машинного обучения для разработки собственной математической модели.

В рамках поставленной цели последовательно были решены следующие задачи:

1. Формирование дата-сета для исследования, представленного данными по пациентам с необходимыми и достаточными признаками для расчетов риска по Фрамингемской шкале, а также достаточное количество пациентов как с наличием, так и отсутствием ССЗ за период не менее 10 лет.

2. Проведение оценки рисков развития ССЗ для данного дата-сета на основе использования классического калькулятора Фрамингемской шкалы.

3. Создание модели расчета рисков ССЗ для данного дата-сета с использованием методов машинного обучения.

4. Сравнение полученных результатов по двум способам расчетов, используя оценки точности и качества моделирования ROC- статистического анализа.

ФОРМИРОВАНИЕ ИСХОДНЫХ ДАННЫХ

Концептуальная схема исследования, показывающая описанные шаги, представлена на *рис. 1*.

Для проведения исследования была выбрана база данных из 2236 пациентов, имеющих и не имеющих ССЗ [15].

Когорта располагала полными данными по основным базовым переменным (пол, возраст, курение, систолическое артериальное давление,

диастолическое артериальное давление, общий холестерин, холестерин липопротеидов высокой плотности, сахарный диабет, прием антигипертензивных препаратов и другие), используемых в обучаемой модели прогнозирования. Состав данных представлен в *таблице 1*.

Базовая выборка имеет средний возраст 60.2 ± 8.29 лет, с 44 до 81 года. Число пациентов, имеющих случаи сердечно-сосудистых заболеваний, составило 523 пациента.

Исходная дата наблюдения была установлена 1 января 2005 года, что позволило всем пациентам в когорте находиться под наблюдением в течение 10 лет, дата конца периода наблюдения была определена как 1 января 2015. Лица, имеющие в анамнезе сердечно-сосудистые заболевания, наследственные нарушения липидного обмена или вне возрастного диапазона были исключены из анализа.

МОДЕЛЬ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ

В качестве методов машинного обучения использована модель искусственной нейронной сети с двумя скрытыми слоями.

Популяция исследования была разделена в наборе данных на «обучающую» выборку (75% из общей извлеченной когорты), в которой были получены алгоритмы риска ССЗ и выборку «валидация» (оставшиеся 25%), которая применялась для тестирования и оценки алгоритмов.

В качестве модели использована последовательная модель с одним входным, тремя скрытыми и одним выходным слоем. Для предотвращения переобучения используется исключение («dropout»). На каждом слое используется функция «dense» для полного соединения слоев друг с другом. В скрытых слоях используется функция активации «relu».



Рис. 1. Концептуальная схема исследования.

Таблица 1

Описание используемых исходных данных для исследования

Признак	Единицы измерения	Среднее значение	Средне-квадратическое отклонение	Min значение	Max значение
Уникальный номер пациента					
Возраст	лет	60,2	8,3	44	81
Пол	женский, мужской				
Систолическое давление		139,0	22,3	86	246
Общий холестерин		237,6	45,3	112	625
Холестерин ЛПВП		48,9	15,6	10	189
Курение	1 – да, 0 – нет				
Антигипертензивная терапия	1 – да, 0 – нет				
Наличие ССЗ	1 -да, 0 -нет				

В качестве оптимизатора алгоритма, который изменяет веса и смещения во время обучения, используется «rmsprop». В качестве функции потерь («loss») используется бинарная кросс-энтропия, в качестве метрики оценки – точность.

Эти алгоритмы были реализованы с помощью открытой библиотеки с исходными текстами scikit-learn, Tensorflow и Keras для языка программирования Python. Гиперпараметры каждой модели определяли с помощью алгоритма поиска GridSearchCV (из той же библиотеки scikit-learn) и 10 K-Fold перекрестной валидации на обучающей когорте для определения значений, которые привели к лучшей производительности.

Результат обучения нейросети показан на рис. 2 и 3.




Рис. 2. Зависимость точности модели (accuracy) от количества итераций (epoch) в сравнении для обучающей и тестовой выборки.

РЕЗУЛЬТАТЫ СРАВНИТЕЛЬНОЙ ОЦЕНКИ МОДЕЛЕЙ

Параметры точности моделей оценивались по методу ROC анализа, основная концепция которого сводится к задаче классификации, чтобы отнести ранее неизвестные моделируемые случаи ССЗ с фактическими болезнями.

В результате классификации может наблюдаться четыре различных ситуации:

- истинно-положительный результат (true-positive, TP) – пациент больной, диагноз положительный;
- ложно-положительный результат (false-positive, FP) – пациент здоров, диагноз положительный;
- истинно-отрицательный результат (true-negative, TN) – пациент здоров, диагноз отрицательный;




Рис. 3. Зависимость функции потерь (loss) от количества итераций (epoch) в сравнении для обучающей и тестовой выборки.



- ложно-отрицательный результат (false-negative, FN) – пациент больной, диагноз отрицательный.

Четыре возможных выхода могут быть сформулированы и оформлены в виде матрицы сопряженности:

Confusion matrix

```
[[TP FP]
 [FN TN]]
```

Значение $Se=TP/(TP+FN)$ – доля истинно положительных случаев или способность алгоритма правильно определять больных, называется чувствительностью.

Значение $Spe=TN/(TN+FP)$ – доля истинно отрицательных случаев или способность алгоритма не принимать здоровых за больных, называется специфичностью.

Экономический эффект от этих ошибок разный: ложно-отрицательный больной придёт с запущенной болезнью, а на дообследование ложно-положительного будут потрачены ресурсы.

Значение $Accuracy=(TP+TN)/(TP+FP+FN+TN)$ – это точность модели, которая характеризует способность модели правильно определять истинно больных и истинно здоровых пациентов [15].

Полученные оценки для модели на основе **нейронной сети**:

Confusion matrix

```
[[493 18]
 [124 36]]
```

Accuracy = 78,84%

$Se = 0,79$, $Sp = 0,67$

Для **Фрамингемской шкалы** прогнозирования риска аналогичные показатели:

Confusion matrix

```
[[134 281]
 [389 1432]]
```

Accuracy = 70.0%

$Se = 0,25$, $Sp = 0,83$

Как показывают сравнительные оценки анализа результатов моделей, Фрамингемская шкала способна наиболее точно определять здоровых пациентов (специфичность выше, чем у нейросети), но при этом чувствительность шкалы ($Se = 0,25$) низкая для определения истинно больных пациентов.

Полученная нами с помощью машинного обучения нейронная сеть показала высокую чувствительность ($Se = 0,79$) и повысила точность моделирования **Accuracy** по сравнению с базовой шкалой **на +8,84%**.

На *рис. 4* представлены Рос-кривые зависимости показателя чувствительности модели от ее специфичности, и площадь AUC под ROC-кривой показывает качество модели. Чем выше показатель AUC, тем выше качество модели.

Полученные показатели AUC:

- для Фрамингемской шкалы: 0,59 (неудовлетворительное качество модели);
- для нейросети: 0,84 (приемлемое качество модели).




Рис. 4. Рос-кривые для результатов моделирования, полученных для Фрамингемской шкалы и модели на основе машинного обучения (нейросеть).



Как показывают результаты оценки точности и качества, модель на основе нейронной сети улучшает результат моделирования по сравнению с Фрамингемской шкалой.

Таким образом, наиболее эффективным и точным способом расчета риска ССЗ является математическая модель на основе нейронной сети с использованием данных для обучения, собранных в популяции, на которой она будет использоваться.

ВЫВОДЫ

1. Расчет суммарного сердечно-сосудистого риска является основой первичной профилактики атеросклероза. Используемые шкалы расчета ССР обладают рядом ограничений, которые сказываются на точности прогноза.

2. Использование алгоритмов машинного обучения, включая алгоритмы глубокого обучения, может значительно повысить точность обученных моделей прогнозирования сердечно-сосудистых рисков. Особенностью является использование датасетов для обучения математической модели на основе данных локальной популяции, что в конечном

счете тоже способствует увеличению точности прогнозирования.

3. Встраивание подобных моделей в СППВР позволяет более быстро и точно получить результат расчета сердечно-сосудистого риска.

4. Выявление пациентов из группы высокого риска в молодом возрасте позволит оптимизировать профиль ФР в среднем возрасте и предупредить или отсрочить развитие ССЗ. Современная стратегия профилактики ССЗ основана на определении суммарного, или общего, риска развития ССЗ и их осложнений. Вместе с тем очевидна необходимость развития данного направления, продолжения исследований по изучению механизмов реализации риска и внедрения новых технологий, разрабатываемых на основе новых знаний и технологий, в профилактическую медицину.

5. Подходы машинного обучения открывают перспективу достижения улучшенной и более индивидуализированной оценки риска ССЗ. Это может помочь движению к персонализированной медицине, лучшей адаптации управления рисками к отдельным пациентам.

ЛИТЕРАТУРА



1. Всемирная организация здравоохранения. Информационный бюллетень «Неинфекционные заболевания». Адрес доступа – <https://www.who.int/ru/news-room/fact-sheets/detail/noncommunicable-diseases>.
2. World Health Organization/ Report «Noncommunicable diseases country profiles». 2018. Адрес доступа – <https://apps.who.int/iris/handle/10665/274512>
3. *De Backer, G.* European Guidelines on cardiovascular disease prevention in clinical practice (version 2012). The fifth joint task force of the European society of cardiology and other societies on cardiovascular disease prevention in clinical practice / *G. De Backer [et al.] // Eur. heart. j.* – 2012. – Vol. 33 (17). – P. 2126.
4. *Kannel W.B., Dawber T.R., Kagan A. et al.* Factors of risk in the development of coronary heart disease – six year follow-up experience. The Framingham Study. *Ann Intern Med* 1961; 55: 33–50.
5. *Conroy R.M., Pyörälä K., Fitzgerald A.P. et al.* Estimation of ten-year risk of fatal cardiovascular disease in Europe: the SCORE project. *Eur Heart J* 2003;24:987–1003.], PROCAM [Assmann G, Cullen P, Schulte H. (2002) Simple scoring scheme for calculating the risk of acute coronary events based on the 10-year follow-up of the prospective cardiovascular Münster (PROCAM) study. *Circulation*; 105(3):310–5.], UKPDS Cardiac Risk [Christianson TJ, Bryant SC, Weymiller AJ, Smith SA, Montori VM. A pen-and-paper coronary risk estimator for office use with patients with type 2 diabetes. *Mayo Clin Proc.* 2006; 81(5): 632–6.
6. *Dawber T.R.* Identification of excess cardiovascular risk. A practical approach. *Minn Med* 1969; 52: 1217–1221.
7. National Institute for Health and Care Excellence. Cardiovascular disease: risk assessment and reduction, including lipid modification. London, UK: National Institute for Health and Care Excellence, 2016.
8. *Castelli, W.P.* Lipids, risk factors and ischaemic heart disease /*W.P. Castelli // Atherosclerosis.* – 1996. – Vol. 124. – P. 9.
9. *Dagenais, G.R.* First coronary heart disease event rates in relation to major risk factors: Quebec cardiovascular study // *Can. j. cardiol.* – 1990. – Vol. 6. – P. 274–280.
10. *Flavell, D.M.* Peroxisome proliferator-activated receptor alpha gene variants influence progression of coronary atherosclerosis and risk of coronary artery disease / *D.M. Flavell // Circulation.* – 2002. – Vol. 105. – P. 1440–1445.



11. Evangelos K. Oikonomou, Michelle C. Williams, Christos P. Kotanidis, Milind Y. Desai, Mohamed Marwan, Alexios S. Antonopoulos, Katharine E. Thomas, Sheena Thomas, Ioannis Akoumianakis, Lampson M. Fan, Sujatha Kesavan, Laura Herdman, Alaa Alashi, Erika Hutt Centeno, Maria Lyasheva, Brian P. Griffin, Scott D. Flamm, Cheerag Shirodaria, Nikant Sabharwal, Andrew Kelion, Marc R. Dweck, Edwin J.R. Van Beek, John Deanfield, Jemma C. Hopewell, Stefan Neubauer, Keith M. Channon, Stephan Achenbach, David E. Newby and Charalambos Antoniades. A novel machine learning-derived radiotranscriptomic signature of perivascular fat improves cardiac risk prediction using coronary CT angiography // European Heart Journal (2019) 0, 1–15, <https://doi.org/10.1093/eurheartj/ehz592>.
12. Laura A. Barrett, BA, Seyedeh Neelufar Payrovnaziri, MS, Jiang Bian, PhD, Zhe He, PhD. Building Computational Models to Predict One-Year Mortality in ICU Patients with Acute Myocardial Infarction and Post Myocardial Infarction Syndrome // <https://arxiv.org/pdf/1812.05072.pdf>.
13. British Heart Foundation funds AI to predict heart disease risk, UR: <https://www.digitalhealth.net/2019/01/british-heart-foundation-artificial-intelligence-heart-disease-risk/>.
14. Quesada J.A., Lopez-Pineda A., Gil-Guillén V.F. et al. Machine learning to predict cardiovascular risk. Int J Clin Pract. 2019; e13389. <https://doi.org/10.1111/ijcp.13389>.
15. Clinical Practice Research Datalink, reference number: CPRD00039761, <https://www.cprd.com/>.
16. Fawcett Tom (2006); An introduction to ROC analysis, Pattern Recognition Letters, 27, 861–874.
17. Морозов С.П., Владимировский А.В., Гомбоевский В.А., Кузьмина Е.С., Ледихова Н.В. Искусственный интеллект: автоматизированный анализ текста на естественном языке для аудита радиологических исследований. Вестник рентгенологии и радиологии. – 2018. – Т. 99. – № 5. – С. 253-258.

Новости отрасли



МЕЖДУНАРОДНЫЙ ФОРУМ РЕГУЛЯТОРОВ РЫНКА МЕДИЦИНСКИХ УСТРОЙСТВ ОБСУДИЛ В РОССИИ ПЕРСПЕКТИВЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ЗДРАВООХРАНЕНИЯ

16 сентября 2019 года в Екатеринбурге в рамках проведения Международного форума регуляторов медицинских изделий (IMDRF) прошел совместный семинар Рабочей группы IMDRF по кибербезопасности и Глобальной Ассоциации Производителей Систем Рентгенографии, медицинских ИТ-технологий и Лучевой Терапии (DITTA) по теме «Искусственный интеллект в здравоохранении».

В работе семинара приняло участие более 200 представителей субъектов обращения медицинских изделий, в том числе регуляторных органов Южной Кореи (MFDS), Российской Федерации (Росздравнадзор), Китая (NMPA), Министерств здравоохранения Германии и Японии, ассоциации DITTA, Всемирной организации здравоохранения (ВОЗ), производителей медицинских изделий (Siemens Healthineers, Philips, GE Healthcare, Shimadzu).

На мероприятии обсуждались ключевые регуляторные проблемы в области искусственного интеллекта (далее – ИИ) в здравоохранении разных стран, связанные с разработкой нормативных требований к программному обеспечению, его использованию, а также с необходимостью адаптации существующей нормативной базы IMDRF.

Генеральный директор Ассоциации «НБМЗ» Борис Зингерман в своем выступлении поведал о процессе создания рынка ИИ для медицинских изделий, а член наблюдательного совета Ассоциации Александр Гусев рассказал о наиболее перспективных разработках в сфере ИИ в системе здравоохранения России.

Источник: <http://nbmz.ru/2019/09/17/boris-zingerman-i-aleksandr-gusev-vystupili-s-dokladami-na-forume-imdrf-v-ekaterinburge/>