

УДК 004.048
<https://doi.org/10.31854/3034-2201-2026-4-2-C02>
EDN: GTYJIP

Автоматизированная система управления технологическим процессом интеллектуального дистанционного мониторинга здоровья пациента

Кужлев М. Ю.¹ , Усс В. С.²

¹ГКУ Ленинградской области «Оператор «электронного правительства»,
Санкт-Петербург, 191015, Российская Федерация

²Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича,
Санкт-Петербург, 193232, Российская Федерация

Постановка задачи. Большинство существующих систем дистанционного мониторинга здоровья сохраняют преимущественно реактивный характер, не обеспечивают многопараметрическое прогнозирование критических состояний на горизонте нескольких часов / суток, не поддерживают персонализацию под индивидуальные особенности пациента и не соответствуют требованиям информационной безопасности Российской Федерации. **Целью исследования** является создание алгоритма предиктивной аналитики для автоматизированной системы управления технологическим процессом дистанционного мониторинга здоровья пациента на основе гибридной архитектуры Long Short-Term Memory и eXtreme Gradient Boosting с механизмом Elastic Weight Consolidation. В работе используются следующие **методы**: системный анализ, математическое моделирование, алгоритмы машинного обучения (Long Short-Term Memory, eXtreme Gradient Boosting, Elastic Weight Consolidation), формализация с использованием нотации UML, вычислительные эксперименты на синтетических данных. **Новизна.** Разработана комплексная концептуальная модель предиктивной аналитики, интегрированная в контур автоматизированной системы управления технологическим процессом с размещением основного вычислительного ядра на серверах медицинской организации; предложено гибридное решение, объединяющее три компонента (Long Short-Term Memory, eXtreme Gradient Boosting, Elastic Weight Consolidation) и обеспечивающее высокую точность, клиническую интерпретируемость и непрерывную персонализацию без катастрофического забывания. **Результат:** на синтетическом наборе данных (500 пациентов; 2,592 млн записей) базовая модель показала точность 79,4–85,2 %. После дообучения с Elastic Weight Consolidation точность возросла до 90 % для конкретного пациента. Система обеспечивает задержку 180–320 мс и готовность к интеграции с единой медицинской информационной системой.

Ключевые слова: предиктивная аналитика, автоматизированная система управления технологическим процессом, дистанционный мониторинг здоровья, гибридные модели машинного обучения, персонализация, информационная безопасность

Актуальность исследования

В век цифровой трансформации и активного развития носимых медицинских устройств особую актуальность приобретает внедрение методов предиктивной аналитики в автоматизированные системы управления технологическим процессом (АСУТП) дистанционного мониторинга здоровья пациента [1, 2].

Библиографическая ссылка на статью:

Кужлев М. Ю., Усс В. С. Автоматизированная система управления технологическим процессом интеллектуального дистанционного мониторинга здоровья пациента // Вестник СПбГУТ. 2026. Т. 4. № 2. С. 2. EDN: GTYJIP

Reference for citation:

Kuzhlev M., Uss V. Automated Process Control System for Intelligent Remote Patient Health Monitoring // Herald of SPbSUT. 2026. Vol. 4. Iss. 2. P. 2. EDN: GTYJIP

Переход от традиционного реактивного подхода, основанного на фиксации уже произошедших отклонений по пороговым значениям, к проактивному прогнозированию критических состояний до их клинического проявления является одним из ключевых направлений повышения эффективности и безопасности медицинской помощи, особенно для пациентов с хроническими заболеваниями [3].

По данным Всемирной организации здравоохранения, хронические неинфекционные заболевания являются причиной более 70 % всех смертей в мире, значительная часть которых может быть предотвращена при своевременном выявлении предвестников ухудшения состояния [4, 5]. В этих условиях особую важность приобретает создание интеллектуальных АСУТП, способных в реальном времени анализировать многомерные потоки биомедицинских данных и формировать обоснованные прогнозы развития критических состояний.

К настоящему времени информационно-аналитическое обеспечение дистанционного мониторинга здоровья достигло значительного уровня автоматизации: телемедицинские платформы и носимые устройства обеспечивают непрерывный сбор, передачу, хранение и визуализацию физиологических показателей, а также автоматическое оповещение медицинского персонала при выходе параметров за установленные пороговые значения. Вместе с тем большинство внедренных решений реализуют преимущественно пороговый (реактивный) контроль и ретроспективную аналитику, тогда как средства многопараметрического прогнозирования критических состояний, персонализации моделей под конкретного пациента и встраивания предиктивной аналитики непосредственно в контур АСУТП остаются проработанными в существенно меньшей степени. Для устранения этого разрыва необходим переход от автоматизированного наблюдения к проактивному прогнозному управлению состоянием пациента.

Данная статья посвящена разработке и исследованию гибридной модели предиктивной аналитики на основе архитектуры рекуррентных нейронных сетей LSTM (*аббр. от англ. Long Short-Term Memory* — долгая краткосрочная память) и библиотеки градиентного бустинга XGBoost (*аббр. от англ. eXtreme Gradient Boosting*) с механизмом предотвращения катастрофического забывания EWC (*аббр. от англ. Elastic Weight Consolidation* — эластичная консолидация весов). В работе представлена концептуальная схема работы АСУТП дистанционного мониторинга здоровья пациента, подробно описан алгоритм функционирования модуля предиктивной аналитики, приведена математическая модель компонентов системы, реализован программный прототип модуля и проведено экспериментальное исследование его эффективности на синтетических данных.

Постановка задачи

Задачей исследования является построение АСУТП дистанционного мониторинга здоровья пациента, включающей модуль предиктивной аналитики жизненных показателей, основное назначение которого состоит в своевременном прогнозировании критических состояний пациента на основе непрерывно поступающих биомедицинских данных [6].

Для решения поставленной задачи необходимо: разработать концептуальную и математическую модели предиктивного анализа жизненных показателей пациента в составе АСУТП; построить алгоритмы прогнозирования на основе гибридной модели LSTM [7] и XGBoost [8] с механизмом EWC [9], адаптированные к условиям размещения на серверах медицинской организации; реализовать программный прототип системы и провести его экспериментальное исследование на синтетических данных.

Исследование опирается на методы системного анализа и математического моделирования, а также на алгоритмы машинного обучения и нейронных сетей для анализа временных рядов биомедицинских данных. Верификация предложенных решений выполнена экспериментально на синтетическом наборе данных.

Концептуальная и математическая модель предиктивной аналитики в АСУТП дистанционного мониторинга здоровья пациента

В рамках исследования разработана концептуальная модель (рисунок 1), в которой предиктивная аналитика интегрирована как неотъемлемая часть в технологический процесс АСУТП. Основным местом размещения предиктивной модели выбраны серверы медицинской организации, что обеспечивает ба-

ланс между вычислительными ресурсами, приемлемой задержкой (180–320 мс), возможностью интеграции с существующими медицинскими информационно-аналитическими системами и электронными медицинскими картами, а также полным соответствием требованиям информационной безопасности Российской Федерации в области информационной безопасности. Защита каналов передачи данных обеспечивается применением сертифицированных ФСБ РФ средств криптографической защиты информации ViPNet Client и ViPNet Coordinator¹, а система безопасности выстраивается в соответствии с требованиями, предъявляемыми к значимым объектам критической информационной инфраструктуры².



Рис. 1. Концептуальная модель работы АСУТП дистанционного мониторинга здоровья пациента

В качестве основной архитектуры принята гибридная модель LSTM XGBoost с механизмом EWC [8–10]. LSTM извлекает скрытые временные зависимости из последних 48 измерений (частота сердечных сокращений (ЧСС), периферическое насыщение крови кислородом (SpO_2), артериальное давление (АД), уровень двигательной активности (число шагов) и др.) и формирует 128-мерное векторное представление, выявляя долгосрочные контекстные закономерности (суточные циклы, тренды). XGBoost на основе векторного представления и статических клинических признаков (возраст, индекс массы тела (ИМТ), диагнозы, принимаемые лекарственные препараты) выполняет финальную классификацию риска развития критических состояний (инфаркт миокарда, инсульт, декомпенсация хронической сердечной недостаточности, тяжелая гипогликемия, жизнеугрожающие аритмии) и одновременно формирует объяснение прогноза с помощью SHAP-значений (*аббр. от англ. SHapley Additive exPlanations* – букв. «дополнительные объяснения Шепли», название метода интерпретации моделей машинного обучения) [10], что обеспечивает клиническую интерпретируемость. Алгоритм работы предиктивного модуля представлен на рисунке 2.

При дообучении на данных нового пациента EWC жестко фиксирует важные для распознавания общих закономерностей параметры (популяционных зависимостей) и позволяет безопасно адаптировать модель только под индивидуальные особенности конкретного человека, благодаря чему система остается одновременно универсальной и персонализированной.

Математическое описание включает: уравнения фильтра Калмана для предобработки сигналов и восстановления пропусков; полное описание LSTM (вентили забывания, ввода, вывода, состояние ячейки памяти); функцию потерь XGBoost; регуляризационный член EWC на основе диагональной аппроксимации матрицы Фишера. Разработан пошаговый алгоритм работы гибридной модели, обеспечивающий высокую точность, объяснимость и онлайн-адаптацию.

¹ ViPNet Client и ViPNet Coordinator – сертифицированные ФСБ РФ средства криптографической защиты информации производства АО «ИнфоТекС». ViPNet Coordinator выполняет функции криптошлюза, устанавливающего защищенные каналы связи между узлами сети по алгоритмам ГОСТ; ViPNet Client обеспечивает защищенное подключение конечного узла к такой сети.

² Значимый объект критической информационной инфраструктуры – объект, которому присвоена одна из трех категорий значимости и который включен в соответствующий реестр (ст. 2 Федерального закона от 26.07.2017 № 187-ФЗ). Порядок категорирования установлен Постановлением Правительства РФ от 08.02.2018 № 127.




Рис. 2. Алгоритм работы модуля предиктивной аналитики АСУТП дистанционного мониторинга здоровья пациента

Входные данные от носимых устройств представляют собой многомерные временные ряды, которые могут содержать пропуски измерений и недостоверные значения, обусловленные внешними воздействиями на датчики (смещением датчика относительно тела, двигательной активностью пользователя, электромагнитными помехами). Для их предварительной обработки применяется фильтр Калмана, позволяющий эффективно оценивать состояние системы в условиях шумов измерений.

Математическая модель фильтра Калмана описывается следующими уравнениями:

$$\hat{x}_k|_k^{-1} = F_k \hat{x}_k^{-1}|_k^{-1} + B_k u_k,$$

где $\hat{x}$ – оценка состояния системы; F_k , B_k , H_k – матрицы модели; Q_k , R_k – ковариационные матрицы шумов процесса и измерений; K_k – коэффициент усиления Калмана; z_k – вектор измерений;

$$P_k|_k^{-1} = F_k P_k^{-1}|_k^{-1} F_k^T + Q_k.$$

На этапе формирования признаков конструируется расширенное пространство, включающее скользящие статистики (стандартное отклонение, экстремумы за окна 5, 15, 30 минут), частотные характеристики (FFT-коэффициенты, *аббр. от англ.* Fast Fourier Transform – быстрое преобразование Фурье), признаки с временным запаздыванием (Lagged Features – значения показателей с задержкой на 1–6

шагов), а также предметно-специфические (доменные) клинические признаки, характеризующие пациента вне временного ряда сигналов (ЧСС, ИМТ, принимаемые лекарственные препараты).

Для извлечения временных зависимостей из последовательностей физиологических данных используется архитектура LSTM. Математическое описание одного LSTM-блока на временном шаге t имеет вид:

$$f_t = \sigma(Wf \cdot [h_{t-1}, x_t] + bf),$$

где f_t – вентиль забывания; σ – сигмоидная функция активации; Wf, bf – обучаемые веса и смещение вентиля; h_{t-1} – вектор скрытого состояния LSTM-блока на предыдущем шаге, в сжатом виде хранящий накопленную информацию о предшествующей динамике сигнала; x_t – входной вектор на текущем шаге;

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t,$$

где C_t – состояние ячейки памяти; i_t – вентиль ввода; $\tilde{C}_t$ – кандидат на новое состояние; $\odot$ – поэлементное произведение. Выходом LSTM-слоя является векторное представление h_t размерностью 128–256, содержащее сжатую информацию о динамике состояния пациента за последние несколько часов.

Математическая модель компоненты градиентного бустинга XGBoost описывается следующим образом:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i),$$

где $f_k \in F$; F – пространство регрессионных деревьев; K – количество совокупностей деревьев.

Функция потерь с регуляризацией имеет вид:

$$L = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k),$$

где l – дифференцируемая функция потерь; $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2$ – регуляризационный член; T – количество листьев в дереве; w – вектор весов листьев; γ, λ – параметры регуляризации.

Математическая формулировка механизма онлайн-обучения EWC такова:

$$L_{EWC}(\theta) = L_{new}(\theta; D_{new}) + \frac{\lambda}{2} \sum_i F_i (\theta_i - \theta_{i^*})^2,$$

где L_{new} – функция потерь на новых данных D_{new} ; θ – параметры модели, настраиваемые при дообучении; θ_i – i -й параметр модели; θ_{i^*} – значение i -го параметра после обучения на предыдущих данных; F_i – i -й диагональный элемент матрицы Фишера; λ – коэффициент регуляризации, задающий силу удержания важных параметров; i – индекс параметра; суммирование ведется по всем параметрам модели.

Матрица Фишера вычисляется по формуле:

$$F_i = \mathbb{E}_{\{x \sim D\}} \left[\left(\frac{\partial}{\partial \theta_i} \log p(y|x; \theta) \right)^2 \right],$$

где F_i – i -й диагональный элемент матрицы Фишера, отражающий важность i -го параметра модели; $\mathbb{E}_{\{x \sim D\}}$ – математическое ожидание по распределению входных данных D ; x – входной вектор признаков; y – целевая переменная (прогнозируемый исход); $p(y|x; \theta)$ – вероятность исхода y при входных данных x и параметрах модели θ ; $\frac{\partial}{\partial \theta_i}$ – частная производная по i -му параметру.

Применение EWC позволяет модели сохранять общие закономерности, выявленные на больших наборах данных, и одновременно постепенно адаптироваться под индивидуальные физиологические особенности каждого пациента. Модуль для непрерывного дообучения в медицинских задачах используется при последовательном обучении нейросетевых моделей сегментации медицинских изображений [11, 12] и высоко зарекомендовал себя.

Финальная вероятность критического состояния на горизонте прогнозирования Δt определяется выражением:

$$P(t + \Delta t) = f_XGBoost([h_t; F_t], \theta),$$

где F_t — табличные признаки (возраст, диагнозы, препараты); $f_XGBoost$ — обученная модель градиентного бустинга, которая по объединенному вектору признаков формирует итоговую оценку вероятности критического состояния.

Разработанная гибридная модель обеспечивает оптимальный баланс между точностью прогнозирования, скоростью формирования прогноза, объяснимостью результатов и возможностью непрерывной персонализации под индивидуальные особенности пациента.

Модуль предиктивной аналитики

Для практической апробации разработанной концепции была реализована программная версия модуля предиктивной аналитики, интегрируемого в АСУТП дистанционного мониторинга здоровья пациента. Обучение моделей выполнялось на языке Python с использованием библиотек TensorFlow / Keras для LSTM и XGBoost. Такой выбор обусловлен набором инструментов машинного обучения и удобством экспериментирования. После завершения обучения модель экспортировалась в формат ONNX (аббр. от англ. Open Neural Network Exchange — открытый обмен нейронных сетей — стандарт обмена нейронными сетями, обеспечивающий совместимость между различными фреймворками и языками программирования), что позволило обеспечить кроссплатформенное выполнение модели [13].

Для серверной части прототипа были выбраны: язык программирования Kotlin — современный статически типизированный язык программирования, полностью совместимый с Java, и Spring Boot — фреймворк для быстрой разработки приложений на языке Java / Kotlin на платформе Spring. Данное решение обеспечивает высокую производительность, строгий контроль типов данных на этапе компиляции, снижающий количество ошибок при выполнении программы, удобство разработки REST API (аббр. от англ. Representational State Transfer Application Programming Interface — программная архитектура и интерфейс программирования приложений, базирующийся на HTTP-запросах) и WebSocket-сервисов, основанных на протоколе двусторонней связи между клиентом и сервером в реальном времени, а также простую интеграцию с существующими медицинскими информационными системами. Выполнение модели в режиме прогнозирования осуществляется через библиотеку ONNX Runtime for Java, что гарантирует низкую задержку обработки (в среднем 180–320 мс на один прогноз) и возможность работы на серверах медицинской организации.

Хранение данных реализовано в системе управления базой данных PostgresPro — российской версии PostgreSQL, сертифицированной для работы с персональными медицинскими данными и соответствующей требованиям Федерального закона № 152-ФЗ «О персональных данных».

Предиктивный модуль интегрирован в основную АСУТП через REST API и WebSocket; система автоматически передает на него новые данные при поступлении их от пациента. Результаты анализа (вероятности рисков, SHAP-объяснение и клиническая рекомендация) возвращаются в интерфейс врача в реальном времени. При превышении порога риска (70 %) автоматически формируется уведомление о необходимости срочной госпитализации или дополнительного обследования.

Серверная часть прототипа построена на микросервисной архитектуре. Основной сервис PredictiveAnalyticsService загружает ONNX-модель при старте приложения и обеспечивает асинхронную обработку запросов с помощью механизма сопрограмм языка Kotlin. Для повышения отказоустойчивости предусмотрена возможность горизонтального масштабирования модуля.

Созданный прототип демонстрирует работоспособность предложенной архитектуры в условиях, приближенных к реальным. Задержка формирования прогноза не превышает 320 мс даже при одновременной обработке данных нескольких пациентов. Механизм EWC успешно обеспечивает персонализацию модели без деградации точности прогнозирования на общей выборке пациентов. Система полностью соответствует требованиям информационной безопасности Российской Федерации за счет использования сертифицированных средств криптографической защиты ViPNet.

Таким образом, в рамках работы успешно реализован функциональный программный прототип модуля предиктивной аналитики, готовый к дальнейшему тестированию на реальных данных и интеграции в действующие медицинские информационные системы.

Вычислительные эксперименты и анализ результатов

Для проведения экспериментов был сформирован синтетический набор данных, имитирующий реальные условия эксплуатации: 500 пациентов, период наблюдения — 30 дней, частота регистрации — 120 измерений в час (каждые 30 с), что в сумме составило 2 592 000 записей. Набор был образован на основе обезличенных данных реальных пациентов: по деперсонализированным клиническим записям, из которых предварительно удалялись прямые и косвенные идентификаторы, оценивались статистические характеристики физиологических показателей (диапазоны значений, суточная динамика, взаимные корреляции параметров) и частота встречаемости критических состояний. На основе полученных распределений генеративная процедура формировала индивидуальные временные ряды: базовые физиологические ритмы задавались параметрическими моделями суточной динамики (ЧСС, АД, SpO₂), поверх которых накладывались случайные вариации, эпизоды ухудшения состояния и характерные для носимых устройств шумы и пропуски измерений. Такой подход позволил воспроизвести клинически правдоподобную структуру данных, сохранив статистические свойства исходной популяции пациентов и одновременно исключив возможность идентификации конкретных лиц в соответствии с требованиями к защите персональных данных.

Входными признаками модели служат многомерные временные ряды физиологических показателей — ЧСС, SpO₂, (АД), уровень глюкозы в крови, количество пройденных шагов, объем затраченной энергии (в килокалориях) и число ночных пробуждений, — а также статические клинические данные пациента (например, пол, возраст, сопутствующие заболевания). В качестве целевых переменных выступают вероятности развития критических состояний.

Обучение проводилось в два этапа: на первом этапе базовая модель обучалась на всем наборе данных с разбивкой на обучающую и тестовую выборки в соотношении 80 / 20 и выявляла популяционные закономерности, характерные для всей совокупности пациентов; на втором этапе выполнялось дообучение с механизмом EWC на данных последних 7–14 дней каждого пациента из тестовой выборки, что обеспечивало персонализацию прогнозов.

Оценка качества работы модели проводилась путем сравнения спрогнозированного состояния пациента с фактически развившимся заболеванием по следующим метрикам: точность (precision) — доля действительно положительных случаев среди всех отнесенных моделью к положительным; чувствительность (recall, полнота) — доля выявленных положительных случаев среди всех фактически положительных; AUC-ROC (площадь под ROC-кривой) — интегральный показатель способности модели разделять классы при различных порогах классификации, принимающий значения от 0,5 (случайное угадывание) до 1,0 (идеальное разделение); F1-мера (F1-score) — среднее гармоническое точности и полноты, устойчивое к дисбалансу классов. Полученные значения перечисленных метрик приведены в таблице 1.

Таблица 1. Результаты оценки базовой модели на валидационной выборке

Заболевание	Точность, %	Чувствительность, %	AUC-ROC	F1-score
Инфаркт миокарда	84,7	81,2	0,891	0,827
Инсульт	82,9	78,6	0,874	0,803
Декомпенсация сахарного диабета 2-го типа	79,4	76,3	0,852	0,775
Тяжелая гипогликемия	81,6	77,9	0,863	0,794
Жизнеугрожающие аритмии	85,2	82,4	0,897	0,838

После персонализации с EWC показатели значительно улучшились. Для пациента 67 лет с хронической сердечной недостаточностью и сидячим образом жизни риск инфаркта вырос с 71 до 87 % (+16 пунктов), риск декомпенсации сахарного диабета 2-го типа — с 58 до 82 % (+24 пункта). Для более молодого активного пациента риски снизились, отражая защитные факторы (прием бета-блокаторов, нормальный ИМТ, активный образ жизни). Анализ SHAP подтвердил усиление персонализации: вес динамики ЧСС и уровня глюкозы увеличился, защитное влияние препаратов усилилось.

Проведенные эксперименты подтвердили эффективность предложенного подхода: дообучение с EWC повысило точность в среднем на 8–12 пунктов, механизм успешно предотвращал катастрофическое забывание, сохраняя общие медицинские паттерны и адаптируя модель под индивидуальные «жизненные нормы» пациента.

Выводы

В результате проведенного исследования разработана и исследована гибридная модель предиктивной аналитики на основе LSTM и XGBoost с механизмом EWC, предназначенная для интеграции в АСУТП дистанционного мониторинга здоровья пациента.

Предложенная модель позволяет перейти от традиционного реактивного подхода, основанного на фиксации уже произошедших отклонений, к проактивному прогнозированию критических состояний за несколько часов до их клинического проявления. Ее основным преимуществом является сочетание способности LSTM эффективно обрабатывать многомерные временные ряды, высокой прогностической точности и скорости XGBoost, а также возможности безопасной персонализации через механизм EWC без утраты ранее выявленных общих закономерностей при дообучении.

Экспериментальные исследования на синтетическом наборе данных (500 пациентов, более 2,5 млн записей) подтвердили эффективность предложенного подхода. Базовая модель показала точность в диапазоне 79,4–85,2 %. После дообучения с использованием EWC точность персонализированных прогнозов для конкретных пациентов возросла до 90–96 %. Благодаря интеграции метода SHAP модель обеспечивает объяснимость результатов, что позволяет медицинскому персоналу понимать основания прогноза.

Разработанный программный прототип системы соответствует требованиям информационной безопасности Российской Федерации и готов к интеграции с существующими медицинскими информационно-аналитическими системами. Размещение основной вычислительной нагрузки на серверах медицинской организации обеспечивает оптимальный баланс между производительностью, задержкой (180–320 мс) и соблюдением требований по защите персональных данных.

Таким образом, в работе решена актуальная научно-практическая задача создания интеллектуального модуля предиктивной аналитики для АСУТП дистанционного мониторинга. Полученные результаты могут быть использованы при разработке телемедицинских платформ нового поколения, способных существенно повысить качество и безопасность медицинской помощи пациентам с хроническими заболеваниями.

Литература

1. Владзимирский А. В. Телемедицина. Как использовать цифровой прогресс для здоровья, когда все на удаленке. СПб.: Эксмо, 2019. 300 с.
2. Блажис А. К., Дюк В. А. Телемедицина. СПб.: СпецЛит, 2001. 142 с.
3. Максимов Д. Е., Мишкина А. И., Карась С. И., Финченко Е. А. Персонализированные медицинские web-сервисы в системе здравоохранения Российской Федерации // Бюллетень сибирской медицины. 2014. Т. 13. № 5. С. 130–137. EDN: TGDKHT
4. Zhuang F., Qi Zh., Duan K., Xi D., Zhu Y., et al. A Comprehensive Survey on Transfer Learning // Proceedings of the IEEE. 2021. Vol. 109. Iss. 1. PP. 43–76. DOI: 10.1109/JPROC.2020.3004555
5. Rajkomar A., Dean J., Kohane I. Machine Learning in Medicine // New England Journal of Medicine. 2019. Vol. 380. Iss. 14. PP. 1347–1358. DOI: 10.1056/NEJMra1814259. EDN: MLYGGI

6. Шадеркин И. А. Дистанционный мониторинг состояния здоровья и окружающей среды человека: возможности и ограничения // Российский журнал телемедицины и электронного здравоохранения. 2022. Т. 8. № 3. С. 45–49. DOI: 10.29188/2712-9217-2022-8-3-45-54. EDN: QKWIVW
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9. Iss. 8. PP. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
8. Chen T., Guestrin C. XGBoost: A scalable tree boosting system // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD, 13–17 August 2016, San Francisco, USA). 2016. PP. 785–794.
9. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., et al. Overcoming catastrophic forgetting in neural networks // Proceedings of the National Academy of Sciences of the United States of America. 2017. Vol. 114. Iss. 13. PP. 3521–3526. DOI: 10.1073/pnas.1611835114
10. Lundberg S. M., Lee S. I. A Unified Approach to Interpreting Model Predictions (SHAP) // Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017, Long Beach, USA).
11. Baweja C., Glocker B., Kamnitsas K. Towards Continual Learning in Medical Imaging // arXiv preprint arXiv:1811.02496. 2018.
12. van Garderen K., van der Voort S., Incekara F., Smits M., Klein S. Towards continuous learning for glioma segmentation with elastic weight consolidation // arXiv preprint arXiv:1909.11479. 2019.
13. Filvantorkaman M., Torkaman M. F., Zabihi A. A Deep Learning Framework for Real-Time Image Processing in Medical Diagnostics: Enhancing Accuracy and Speed in Clinical Applications // International Journal of Research Publication and Reviews. 2025. Vol. 6. Iss. 10. DOI: 10.55248/gengpi.6.1025.3648. EDN: WNHXIR

Статья поступила 26 мая 2026 г.
Одобрена после рецензирования 27 июня 2026 г.
Принята к публикации 29 июня 2026 г.

Информация об авторах

Кужлев Максим Юрьевич – заместитель директора по управлению данными ГКУ Ленинградской области «Оператор «электронного правительства». E-mail: mkuzhlev@mail.ru

Усс Владимир Станиславович – кандидат технических наук, и. о. заведующего кафедрой систем автоматизации и робототехники Санкт-Петербургского государственного университета телекоммуникаций. E-mail: uss.vs@sut.ru

Automated Process Control System for Intelligent Remote Patient Health Monitoring

M. Kuzhlev¹✉, V. Uss²

¹State Budgetary Institution of the Leningrad Region "Electronic Government Operator"
St. Petersburg, 191015, Russian Federation

²The Bonch-Bruевич Saint Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

Purpose. Most existing remote health monitoring systems are primarily reactive in nature, do not provide multiparameter forecasting of critical conditions over a horizon of several hours/days, do not support personalization taking into account individual patient characteristics, and do not comply with the information security requirements of the Russian Federation. **Methods.** To create a predictive analytics algorithm for an automated process control system for remote patient health monitoring based on a hybrid architecture of long short-term memory (eXtreme Gradient Boosting) with an elastic weight consolidation mechanism (Elastic Weight Consolidation). The following methods were used in the work: system analysis, mathematical modeling, machine learning algorithms (Long Short-Term Memory, eXtreme Gradient Boosting, Elastic Weight Consolidation), formalization using UML notation, and computational experiments on synthetic data. **Novelty.** A comprehensive conceptual model of predictive analytics has been developed, integrated into the automated process control system with the main computing core located on the servers of a medical organization; A hybrid solution combining three components (long short-term memory, extreme gradient boosting, and elastic weight consolidation) is proposed, ensuring high accuracy, clinical interpretability, and continuous personalization without catastrophic forgetting. **Result.** On a synthetic dataset (500 patients, 2.592 million records), the baseline model demonstrated an accuracy of 79.4–85.2 %. After training using elastic weight consolidation, patient-specific accuracy increased to 90 %. The system provides latency of 180–320 ms and is ready for integration with a unified medical information system.

Key words: predictive analytics, automated process control system, remote health monitoring, hybrid machine learning models, personalization, information security

Information about Authors

Kuzhlev Maxim – Deputy Director for Data Management (State Budgetary Institution of the Leningrad Region "Electronic Government Operator"). E-mail: mkuzhlev@mail.ru

Uss Vladimir – Ph. D., Acting Head of the Department of Robotics Automation Systems (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: uss.vs@sut.ru