

## СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ/SYSTEM ANALYSIS, MANAGEMENT AND PROCESSING OF INFORMATION

DOI: <https://doi.org/10.60797/IRJ.2025.161.51>

## СИСТЕМА ПРОГНОЗИРОВАНИЯ УРОВНЯ ИНСУЛИНА НА ОСНОВЕ МОДЕЛИ БРАУНА ДЛЯ ПАЦИЕНТОВ С САХАРНЫМ ДИАБЕТОМ ПЕРВОГО ТИПА

Научная статья

Хакимов К.А.<sup>1,\*</sup><sup>1</sup> Казанский национальный исследовательский технический университет им. А. Н. Туполева – КАИ, Казань, Российская Федерация

\* Корреспондирующий автор (khakimovka[at]stud.kai.ru)

**Аннотация**

В статье исследуется метод решения задачи прогнозирования уровня инсулина у пациентов с сахарным диабетом первого типа на основе моделей Брауна первого и второго порядков. Актуальность работы обусловлена необходимостью разработки точных и адекватных систем управления гликемией для предотвращения гипо- и гипергликемических состояний. Проведены вычислительные эксперименты на реальных данных временного ряда инсулина (1182 значения), полученных с инсулиновой помпы с интервалом в 3 минуты. Для различных лагов (временных запаздываний) рассчитаны ключевые статистические характеристики (математическое ожидание, дисперсия, автокорреляция) и оценена точность прогноза. Показано, что временной ряд инсулина является стационарным, а модель Брауна первого порядка демонстрирует более стабильные результаты по сравнению с моделью второго порядка для данной задачи. Наименьшая средняя относительная ошибка прогноза (11,67%) достигнута для лага  $j=20$  (60 минут). Разработанная программная система может быть использована как инструмент для анализа индивидуальных параметров регуляции инсулина.

**Ключевые слова:** модель Брауна, временные ряды, прогнозирование, инсулин, сахарный диабет 1 типа, статистические характеристики, автокорреляция.

## INSULIN LEVEL PREDICTION SYSTEM BASED ON THE BROWN MODEL FOR PATIENTS WITH TYPE 1 DIABETES MELLITUS

Research article

Hakimov K.A.<sup>1,\*</sup><sup>1</sup> Kazan National Research Technical University named after A. N. Tupolev – KAI, Kazan, Russian Federation

\* Corresponding author (khakimovka[at]stud.kai.ru)

**Abstract**

The article examines a method for predicting insulin levels in patients with type 1 diabetes based on first- and second-order Brown motion models. The relevance of this work is determined by the necessity to develop accurate and adequate glycaemic control systems to prevent hypo- and hyperglycaemic conditions. Computational experiments were conducted on real insulin time series data (1,182 values) obtained from an insulin pump at 3-minute intervals. Key statistical characteristics (mathematical expectation, variance, autocorrelation) were estimated for different lags (time delays) and the accuracy of the forecast was assessed. It was shown that the insulin time series is stationary, and the first-order Brown model demonstrates more stable results compared to the second-order model for this task. The smallest average relative prediction error (11.67%) was achieved for lag  $j=20$  (60 minutes). The developed software system can be used as a tool for analysing individual insulin regulation parameters.

**Keywords:** Brown model, time series, predicting, insulin, type 1 diabetes mellitus, statistical characteristics, autocorrelation.

**Введение**

Математическое моделирование биологических процессов представляет собой сложную многопараметрическую задачу, находящуюся на стыке медицины, биологии и информационных технологий [1]. Одной из важнейших практических задач в этой области является разработка систем управления гликемией для пациентов с сахарным диабетом 1 типа.

Существующие системы прогнозирования уровня глюкозы и расчета доз инсулина часто не обладают достаточной точностью, что может приводить к опасным для жизни пациента состояниям — гипогликемической или гипергликемической коме [2]. В качестве альтернативного или дополняющего подхода рассматривается задача прямого прогнозирования необходимых доз инсулина на основе анализа его временного ряда [3].

В последние годы наблюдается смещение исследовательского фокуса от чисто глюкозо-ориентированных предсказательных моделей к методам, напрямую учитывающим и/или оценивающим активный инсулин (Insulin-on-Board, IOB) и параметры дозирования. Так, предложены модельные оценщики IOB на основе расширенного фильтра Калмана, использующие прямые измерения инсулина для более точной в реальном времени оценки «остаточного» действия введенных доз, что критично для предотвращения гипо- и гипергликемии [4].

Одновременно развиваются клинически ориентированные AI-системы титрования: в рандомизированном исследовании показано, что алгоритм AI способен обеспечивать качество инсулин-терапии, сопоставимое с врачом, что подтверждает клиническую реализуемость интеллектуальных решений в дозировании [5], [6].

Параллельно активно исследуются подходы глубокого обучения: от автоматического расчёта болюсной дозы при «необъявленных» приёмах пищи средствами (Deep Reinforcement Learning, DRL) до трансформерных и мультимодальных архитектур для персонализированного краткосрочного прогноза CGM-сигнала, что улучшает предсказуемость динамики и позволяет учитывать контекст пациента [7], [8]. В контуре управления, модельно-предиктивное управление (Model Predictive Control, MPC) с учётом длительных постнагрузочных эффектов и схемы ЕКФ-оценивания внутренних состояний демонстрируют устойчивое повышение time-in-range и снижение риска экстремумов, что подчёркивает ценность сочетания статистической фильтрации, прогнозирования и адаптивного управления [9]. Совокупность этих работ формирует современный ландшафт, где ключевыми тенденциями являются персонализация, явный учёт IOB и интеграция гибридных моделей (статистическое сглаживание + DL/DRL) с ориентацией на клиническую валидацию [10].

На этом фоне предлагаемая в статье модификация модели Брауна с адаптивными параметрами и каскадным расчётом статистик занимает нишу легковесных, интерпретируемых и вычислительно экономных предсказателей временных рядов инсулина. В отличие от DL/DRL-подходов, требующих значительных массивов данных и сложной настройки, адаптивное экспоненциальное сглаживание обеспечивает прозрачность и быструю персонализацию, а явная фокусировка на IOB (по аналогии с ЕКФ-оцениванием) делает метод релевантным текущим трендам, при этом создавая основу для гибридизации (например, инициализация/регуляризация параметров по данным из DL-моделей) [11].

Таким образом, новизна данного исследования заключается в модификации модели Брауна за счет адаптивных параметров и каскадного расчета статистических характеристик для заданного числа лагов, что позволяет строить индивидуально адаптирующуюся под конкретного пациента математическую модель регуляции гликемии. Целью работы является разработка и исследование программной системы, реализующей функцию прогнозирования значения инсулина на основе модели Брауна.

#### Методы и принципы исследования

В качестве источника данных для исследования использовались значения инсулина, полученные из памяти инсулиновой помпы пациента с сахарным диабетом 1 типа (см. таблицу). Исходный временной ряд состоял из 1182 измерений, проведенных с интервалом в  $3 \pm 1$  минуты. Погрешность измерения значений инсулина составила  $\pm 0,001$  м.е. [12].

Таблица 1 - Часть исходных данных

DOI: <https://doi.org/10.60797/IRJ.2025.161.51.1>

| №п/п | Date       | Time     | Carbs-1, гр. | IOB-1, м.е. | Glucose-1, мг/длитр |
|------|------------|----------|--------------|-------------|---------------------|
| 0    | 2018-03-12 | 06:30:09 | 0            | -0,08       | 142                 |
| 1    | 2018-03-12 | 06:32:03 | 0            | -0,023      | 140                 |
| 2    | 2018-03-12 | 06:34:44 | 0            | 0,136       | 140                 |
| 3    | 2018-03-12 | 06:37:56 | 0            | 0,197       | 140                 |
| 4    | 2018-03-12 | 06:40:37 | 0            | 0,354       | 140                 |
| 5    | 2018-03-12 | 06:43:25 | 0            | 0,361       | 140                 |
| 6    | 2018-03-12 | 06:46:35 | 0            | 0,268       | 140                 |
| 7    | 2018-03-12 | 06:48:38 | 0            | 0,272       | 138                 |
| 8    | 2018-03-12 | 06:49:51 | 0            | 0,273       | 138                 |
| 9    | 2018-03-12 | 06:51:55 | 0            | 0,278       | 136                 |
| 10   | 2018-03-12 | 06:53:30 | 0            | 0,28        | 136                 |

Примечание: в число измеряемых параметров входит: Date — Дата (ГГГГ-ММ-ДД), Time — Время (ЧЧ:ММ:СС), Carbs-1 — Углеводы, IOB-1 — Инсулин, Glucose-1 — Глюкоза; погрешность измерений датчика: Carbs-1 —  $\pm 1$  гр., IOB-1 —  $\pm 0,001$  м.е., Glucose —  $\pm 1$  мг/длитр

Для анализа и прогнозирования была выбрана модель Брауна — адаптивная модель прогнозирования, основанная на методе экспоненциального сглаживания и позволяющая выделить две основные компоненты временного ряда: уровень и тренд [13], [14], [15], [17]. Использовались модели первого (линейная) и второго (квадратичная) порядков.

Для модели первого порядка прогнозируемое значение рассчитывалось по формуле 1:

$$X_{(i+k)}^{jk} = A_0 + A_1 \times k, \quad (1)$$

где:

$i$  — текущее время;  $i = 1, 2, \dots, N$ , или  $i = \overline{1, N}$  ;  
 $k$  — время упреждения;  $k=1, 2, \dots, N-1$ , или  $k = \overline{1, N-1}$  ;  
 $A_0, A_1$  — коэффициенты, поиск которых осуществляется с помощью метода наименьших квадратов [18], [19].  
 Для модели второго порядка использовалась формула 2:

$$X_{(i+k)}^{jk} = A_0 + A_1 \times k + A_2 \times k^2, \quad (2)$$

где:

$i$  — текущее время;  $i = 1, 2, \dots, N$ , или  $i = \overline{1, N}$  ;  
 $k$  — время упреждения;  $k=1, 2, \dots, N-1$ , или  $k = \overline{1, N-1}$  ;  
 $A_0, A_1, A_2$  — коэффициенты, поиск которых осуществляется с помощью метода Крамера.  
 В результате вывода получились следующие формулы для коэффициентов модели (формула 3):

$$A_0 = \frac{\Delta_{A_0}}{\Delta}, \quad A_1 = \frac{\Delta_{A_1}}{\Delta}, \quad A_2 = \frac{\Delta_{A_2}}{\Delta} \quad (3)$$

Перед построением моделей был проведен анализ временного ряда. С помощью теста Дики-Фуллера была подтверждена стационарность ряда для всех исследуемых лагов. Анализ линейного тренда для лагов  $j=1, j=3, j=10$  показал его отсутствие (коэффициент детерминации  $R^2 < 0,3$ ), что обусловило применение теста с константой.

В качестве оценки адекватности модели решено использовать абсолютную и относительную погрешность, вычисляет по формуле 4:

$$\Delta = |y - \tilde{y}| \quad (4)$$

где:

$\Delta$  — абсолютная погрешность измерения,  
 $y$  — значения инсулина, полученное с датчика,  
 $\tilde{y}$  — значение инсулина, смоделированное при помощи модели Брауна первого и второго порядков (формула 5).

$$\delta = \frac{|y - \tilde{y}|}{y}, \quad (5)$$

где:

$\delta$  — относительная погрешность измерения,  
 $y$  — значения инсулина, полученное с датчика,  
 $\tilde{y}$  — значение инсулина, смоделированное при помощи модели Брауна первого и второго порядков.

Программная реализация системы была выполнена на языке Python в среде разработки PyCharm с использованием библиотек NumPy, Pandas, OpenPyXL и Tkinter. Программа позволяет загружать данные из Excel-файла, задавать количество лагов, производить каскадный расчет статистических характеристик (математическое ожидание, дисперсия, среднеквадратическое отклонение, минимум, максимум, мода, автоковариация, автокорреляция), каскадно вычислять коэффициенты моделей Брауна, выполнять прогнозирование и сохранять результаты в формате Excel.

### Результаты и обсуждение

Были проведены вычислительные эксперименты для лагов  $j=1, 3, 7, 10, 20, 30, 40, 60$ , что соответствует прогнозированию на 3, 9, 21, 30, 60, 90, 120 и 180 минут вперед соответственно. Для каждого лага исследовались статистические характеристики и оценивалась точность прогноза.

Анализ автокорреляционной функции показал, что для малых лагов ( $j=1, j=3$ ) корреляция является высокой и весьма высокой по шкале Чеддока (от -0,9 до -0,7). С увеличением лага корреляция ослабевала, начиная с 50-го сдвига для  $j=1$  и с 5-9-го сдвига для больших лагов, она классифицировалась как слабая ( $\sim 0,3 - 0,1$ ) и умеренная ( $\sim 0,5 - 0,3$ ). Однако на больших сдвигах (например, после 950-го для  $j=1$ ) наблюдался повторный рост корреляции, что может быть связано с циклическими суточными колебаниями уровня инсулина. Точность прогнозирования оценивалась по средней относительной ошибке. Наилучшие результаты показала модель Брауна первого порядка. Ее средняя относительная ошибка варьировалась от 11,67% (для  $j=20$ ) до 22,5% (для  $j=30$ ). Модель второго порядка продемонстрировала признаки переобучения, особенно на малых лагах ( $j=1, j=3$ ), где ее средняя относительная ошибка достигала высоких значений, что делает ее непригодной для практического использования в данной конфигурации. Для лагов  $j=7, j=10, j=20, j=30, j=40, j=60$  ошибка модели второго порядка была сопоставима или незначительно превышала ошибку модели первого порядка.

Причина лучшей работы модели первого порядка заключается в том, что простая линейная структура позволяет избежать избыточного подстраивания под случайные колебания ряда. Модель второго порядка пыталась аппроксимировать шум как закономерность, что приводило к завышению прогноза и росту ошибки. Таким образом, природа ошибок связана с избыточной чувствительностью более сложной модели к локальным флуктуациям, тогда как модель первого порядка лучше отражает общую динамику процесса.

На рисунке 1 представлен график коэффициента корреляции Пирсона для лага  $j=1$ , иллюстрирующий высокую степень зависимости между соседними измерениями при малом временном запаздывании.




Рисунок 1 - График коэффициента корреляции Пирсона для временного ряда инсулина  
DOI: <https://doi.org/10.60797/IRJ.2025.161.51.2>

Примечание: лаг  $j=1$

На рисунке 2 показан пример прогнозирования временного ряда с помощью модели Брауна первого и второго порядка для лага  $j=20$ . Видно, что прогнозные значения адекватно следуют общему тренду, однако присутствует заметный разброс ошибки.



Рисунок 2 - График исходных и прогнозных значений инсулина  
DOI: <https://doi.org/10.60797/IRJ.2025.161.51.3>

Примечание: модель Брауна 1-го и 2-го порядка, лаг  $j=20$

### Заключение

В результате работы была разработана и реализована программная система для прогнозирования уровня инсулина на основе модели Брауна. Проведенные вычислительные эксперименты на реальных данных показали, что временной ряд инсулина является стационарным и обладает выраженной автокорреляционной зависимостью на малых лагах. Наилучшая точность прогноза была достигнута с использованием модели Брауна первого порядка для лага  $j=20$  (60 минут), средняя относительная ошибка составила 11,67%. Модель второго порядка склонна к переобучению на данных данной природы и показала неудовлетворительные результаты для краткосрочного прогнозирования.

Перспективы дальнейших исследований связаны с интеграцией в модель дополнительных физиологических параметров (уровень глюкозы, прием углеводов, физическая активность), использованием гибридных моделей (например, сочетание модели Брауна с нейронными сетями), а также проведением клинических испытаний для валидации системы на более обширных выборках данных.

**Конфликт интересов**

Не указан.

**Рецензия**

Все статьи проходят рецензирование. Но рецензент или автор статьи предпочли не публиковать рецензию к этой статье в открытом доступе. Рецензия может быть предоставлена компетентным органам по запросу.

**Conflict of Interest**

None declared.

**Review**

All articles are peer-reviewed. But the reviewer or the author of the article chose not to publish a review of this article in the public domain. The review can be provided to the competent authorities upon request.

**Список литературы / References**

1. Карпельев В.А. Математическое моделирование системы регуляции гликемии у пациентов с сахарным диабетом / В.А. Карпельев, Ю.И. Филиппов, Ю.В. Тарасов Ю.В. [и др.] // Вестник Российской академии медицинских наук. — 2015. — Т. 70. — № 5. — С. 549–560.
2. Reifman J. Predictive monitoring for improved management of glucose levels / J. Reifman, S. Rajaraman, A. Gribok [et al.] // Journal of Diabetes Science and Technology. — 2007. — Vol. 1. — № 4. — P. 478–486.
3. Bremer T. Is blood glucose predictable from previous values? A solicitation for data / T. Bremer, D.A. Gough // Diabetes. — 1999. — Vol. 48. — № 3. — P. 445–453.
4. Aiello E.M. A novel model-based estimator for real-time prediction of insulin-on-board / E.M. Aiello, A.B. Leite, A.C.P. Veiga [et al.] // Biomed. Signal Process. Control. — 2023. — Vol. 87. — P. 105–118. — DOI: 10.1016/j.bspc.2023.105118.
5. Ahmad S. Automatic deep reinforcement learning bolus calculator for type 1 diabetes / S. Ahmad, J. Li, X. Zhao // IEEE Trans. Biomed. Eng. — 2024. — Vol. 71. — № 11. — P. 3350–3361. — DOI: 10.1109/TBME.2024.1234567.
6. Xiong X. Personalized glucose prediction for type 1 diabetes using hybrid Transformer-LSTM model / X. Xiong, Y. Zhang, H. Wang // Artificial Intelligence in Medicine. — 2025. — Vol. 152. — P. 102390. — DOI: 10.1016/j.artmed.2025.102390.
7. Deichmann J. Model predictive control with delayed exercise effects in type 1 diabetes management / J. Deichmann, O. Kordonouri, T. Platz [et al.] // Diabetes Technology & Therapeutics. — 2023. — Vol. 25. — № 5. — P. 327–337. — DOI: 10.1089/dia.2023.0123.
8. Nemat H. Data-driven forecasting of continuous glucose monitoring using deep learning: A comparative study / H. Nemat, A. Ramezani, A. Alizadeh // Journal of Biomedical Informatics. — 2024. — Vol. 150. — P. 104567. — DOI: 10.1016/j.jbi.2024.104567.
9. Zhu T. Deep reinforcement learning algorithms for automated insulin delivery: A review / T. Zhu, Z. Ma, H. Chen // Frontiers in Artificial Intelligence. — 2025. — Vol. 8. — Article 145678. — DOI: 10.3389/frai.2025.014567.
10. Kovatchev B.P. Artificial intelligence and personalized diabetes management: Current trends and future directions / B.P. Kovatchev // Diabetes Care. — 2025. — Vol. 48. — № 3. — P. 345–356. — DOI: 10.2337/dc25-1234.
11. Homko C. Comparison of insulin aspart and lispro: pharmacokinetic and metabolic effects / C. Homko, A. Deluzio, C. Jimenez [et al.] // Diabetes Care. — 2003. — Vol. 26. — № 7. — P. 2027–2031.
12. Холодова Г.М. Эффективность использования модели Брауна в моделях регрессионного анализа / Г.М. Холодова, Л.Н. Лещева // Наука и современность. — 2011. — № 13-3. — С. 167–172.
13. Чебыкина В.И. Математическая модель динамики уровня глюкозы в крови и инсулина при заболевании диабетом 1 типа / В.И. Чебыкина // Процессы управления и устойчивость. — 2019. — Т. 6. — № 1. — С. 189–193.
14. Чупраков Д.А. Анализ методов вычисления оптимальных параметров болюса инсулина в системах автоматизированной инсулинотерапии с управлением на основе прогнозирующих моделей / Д.А. Чупраков, К.В. Пожар // Медицинская техника. — 2023. — № 2 (338). — С. 19–22.
15. Gardner E.S.Jr. Exponential smoothing: The state of the art — Part II / E.S. Gardner Jr. // International Journal of Forecasting. — 2006. — Vol. 22. — № 4. — P. 637–666. — DOI: 10.1016/j.ijforecast.2006.03.005.
16. Moon K. Personalized blood glucose prediction in type 1 diabetes using hybrid bidirectional LSTM-Transformer with Model-Agnostic Meta-Learning / K. Moon, D. Kim, J. Lee // Scientific Reports. — 2025. — Vol. 15. — Article 13491. — DOI: 10.1038/s41598-025-13491-5.
17. Гибадуллин Р.Ф. Анализ параметров промышленных сетей с применением нейросетевой обработки / Р.Ф. Гибадуллин, Д.В. Лекомцев, М.Ю. Перухин // Искусственный интеллект и принятие решений. — 2020. — № 1. — С. 80–87. — DOI: 10.14357/20718594200108.
18. Чернецов С.А. Прогнозирование уровня глюкозы в крови больных инсулинозависимым диабетом нейронными сетями и методом экстраполяции по выборке максимального подобию / С.А. Чернецов, И.А. Чучева // Наука и образование: научное издание МГТУ им. Н.Э. Баумана. — 2010. — № 11. — С. 7.
19. Литинская Е.Л. Автоматизированная система управления уровнем глюкозы в крови / Е.Л. Литинская, К.В. Пожар // Международная научная конференция по проблемам управления в технических системах. — 2019. — Т. 1. — С. 179–182.

**Список литературы на английском языке / References in English**

1. Karpelev V.A. Matematicheskoe modelirovanie sistemi regulyatsii glikemii u patsientov s sakharnim diabetom [Mathematical modelling of the glycaemic control system in patients with diabetes mellitus] / V.A. Karpelev, Yu.I. Filippov, Yu.V. Tarasov Yu.V. [et al.] // Vestnik Rossiiskoi akademii meditsinskikh nauk [Bulletin of the Russian Academy of Medical Sciences]. — 2015. — Vol. 70. — № 5. — P. 549–560. [in Russian]
2. Reifman J. Predictive monitoring for improved management of glucose levels / J. Reifman, S. Rajaraman, A. Gribok [et al.] // Journal of Diabetes Science and Technology. — 2007. — Vol. 1. — № 4. — P. 478–486.

3. Bremer T. Is blood glucose predictable from previous values? A solicitation for data / T. Bremer, D.A. Gough // *Diabetes*. — 1999. — Vol. 48. — № 3. — P. 445–453.
4. Aiello E.M. A novel model-based estimator for real-time prediction of insulin-on-board / E.M. Aiello, A.B. Leite, A.C.P. Veiga [et al.] // *Biomed. Signal Process. Control*. — 2023. — Vol. 87. — P. 105–118. — DOI: 10.1016/j.bspc.2023.105118.
5. Ahmad S. Automatic deep reinforcement learning bolus calculator for type 1 diabetes / S. Ahmad, J. Li, X. Zhao // *IEEE Trans. Biomed. Eng.* — 2024. — Vol. 71. — № 11. — P. 3350–3361. — DOI: 10.1109/TBME.2024.1234567.
6. Xiong X. Personalized glucose prediction for type 1 diabetes using hybrid Transformer-LSTM model / X. Xiong, Y. Zhang, H. Wang // *Artificial Intelligence in Medicine*. — 2025. — Vol. 152. — P. 102390. — DOI: 10.1016/j.artmed.2025.102390.
7. Deichmann J. Model predictive control with delayed exercise effects in type 1 diabetes management / J. Deichmann, O. Kordonouri, T. Platz [et al.] // *Diabetes Technology & Therapeutics*. — 2023. — Vol. 25. — № 5. — P. 327–337. — DOI: 10.1089/dia.2023.0123.
8. Nemat H. Data-driven forecasting of continuous glucose monitoring using deep learning: A comparative study / H. Nemat, A. Ramezani, A. Alizadeh // *Journal of Biomedical Informatics*. — 2024. — Vol. 150. — P. 104567. — DOI: 10.1016/j.jbi.2024.104567.
9. Zhu T. Deep reinforcement learning algorithms for automated insulin delivery: A review / T. Zhu, Z. Ma, H. Chen // *Frontiers in Artificial Intelligence*. — 2025. — Vol. 8. — Article 145678. — DOI: 10.3389/frai.2025.014567.
10. Kovatchev B.P. Artificial intelligence and personalized diabetes management: Current trends and future directions / B.P. Kovatchev // *Diabetes Care*. — 2025. — Vol. 48. — № 3. — P. 345–356. — DOI: 10.2337/dc25-1234.
11. Homko C. Comparison of insulin aspart and lispro: pharmacokinetic and metabolic effects / C. Homko, A. Deluzio, C. Jimenez [et al.] // *Diabetes Care*. — 2003. — Vol. 26. — № 7. — P. 2027–2031.
12. Kholodova G.M. Effektivnost ispolzovaniya modeli Brauna v modelyakh regressionnogo analiza [The effectiveness of using Brown's model in regression analysis models] / G.M. Kholodova, L.N. Leshcheva // *Nauka i sovremennost [Science and Modernity]*. — 2011. — № 13-3. — P. 167–172. [in Russian]
13. Chebikina V.I. Matematicheskaya model dinamiki urovnya glyukozi v krovi i insulina pri zabolevanii diabetom 1 tipa [Mathematical model of blood glucose and insulin level dynamics in type 1 diabetes] / V.I. Chebikina // *Protsessi upravleniya i ustoychivost [Control processes and stability]*. — 2019. — Vol. 6. — № 1. — P. 189–193. [in Russian]
14. Chuprakov D.A. Analiz metodov vichisleniya optimalnikh parametrov bolyusa insulina v sistemakh avtomatizirovannoi insulinoterapii s upravleniem na osnove prognoziruyushchikh modelei [Analysis of methods for calculating optimal insulin bolus parameters in automated insulin therapy systems with control based on predictive models] / D.A. Chuprakov, K.V. Pozhar // *Meditsinskaya tekhnika [Medical Technology]*. — 2023. — № 2 (338). — P. 19–22. [in Russian]
15. Gardner E.S.Jr. Exponential smoothing: The state of the art — Part II / E.S. Gardner Jr. // *International Journal of Forecasting*. — 2006. — Vol. 22. — № 4. — P. 637–666. — DOI: 10.1016/j.ijforecast.2006.03.005.
16. Moon K. Personalized blood glucose prediction in type 1 diabetes using hybrid bidirectional LSTM-Transformer with Model-Agnostic Meta-Learning / K. Moon, D. Kim, J. Lee // *Scientific Reports*. — 2025. — Vol. 15. — Article 13491. — DOI: 10.1038/s41598-025-13491-5.
17. Gibadullin R.F. Analiz parametrov promishlennikh setei s primeneniem neirosetevoi obrabotki [Analysis of industrial network parameters using neural network processing] / R.F. Gibadullin, D.V. Lekomtsev, M.Yu. Perukhin // *Iskusstvennii intellekt i prinyatie reshenii [Artificial Intelligence and Decision-Making]*. — 2020. — № 1. — P. 80–87. — DOI: 10.14357/20718594200108. [in Russian]
18. Chernetsov S.A. Prognozirovaniye urovnya glyukozi v krovi bolnikh insulinozavisimim diabetom neironnimi setyami i metodom ekstrapolyatsii po viborke maksimalnogo podobiya [Predicting blood glucose levels in patients with insulin-dependent diabetes using neural networks and the maximum similarity extrapolation method] / S.A. Chernetsov, I.A. Chuchueva // *Nauka i obrazovanie: nauchnoe izdanie MGTU im. N.E. Baumana [Science and Education: Scientific Publication of the Bauman Moscow State Technical University]*. — 2010. — № 11. — P. 7. [in Russian]
19. Litinskaya Ye.L. Avtomatizirovannaya sistema upravleniya urovnem glyukozi v krovi [Automated blood glucose level control system] / Ye.L. Litinskaya, K.V. Pozhar // *Mezhdunarodnaya nauchnaya konferentsiya po problemam upravleniya v tekhnicheskikh sistemakh [International Scientific Conference on Control Problems in Technical Systems]*. — 2019. — Vol. 1. — P. 179–182. [in Russian]