

УДК 004.62

## Схемы интерполяции оптимальных значений параметров вентиляционного потока в зависимости от значений показателей пациента при искусственной вентиляции легких

© 2025 г. С. Г. Климанов<sup>1</sup>, А. В. Крянев<sup>1,2</sup>, А. А. Котляров<sup>3</sup>, Д. С. Смирнов<sup>1</sup>, И. В. Сопенко<sup>3</sup>, В. А. Трикозова<sup>1</sup>, Д. Д. Царева<sup>1</sup>

<sup>1</sup> Национальный исследовательский ядерный университет «МИФИ», Москва, 115409, Россия

<sup>2</sup> Объединенный институт ядерных исследований, Дубна, 141980, Россия

<sup>3</sup> Обнинский институт атомной энергетики – филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ»», г. Обнинск, Калужская область, 249039, Россия

В статье на основе базы исходных данных успешного лечения пациентов предлагаются две схемы интерполяции оптимальных значений параметров вентиляционного потока при искусственной вентиляции легких (ИВЛ) рассматриваемого пациента. На математическом уровне выбор оптимальных значений параметров вентиляционного потока в зависимости от значений показателей текущего состояния пациента является задачей многомерного нелинейного регрессионного анализа. Первая схема основана на применении математического аппарата искусственных нейронных сетей. Вторая схема основана на применении математического аппарата метрического анализа, созданного на кафедре прикладной математики МИФИ и в настоящее время используемого при математической обработке данных и решения задач оптимизации в различных прикладных областях. Реализация обеих схем позволяет использовать накопленные данные по успешному лечению пациентов на аппаратах ИВЛ аналогичных заболеваний легких для рассматриваемого конкретного пациента. Обе схемы позволяют в процессе лечения пациента адаптировать оптимальные значения параметров вентиляционного потока к текущим показаниям пациента, подключенного к аппарату ИВЛ. В дальнейшем планируется совместное объединенное использование этих двух схем интерполяции для получения более точного и надежного конечного результата решения вышеуказанной задачи оптимальной интерполяции.

**Ключевые слова:** искусственная вентиляция легких, показания пациентов, интерполяция, оптимальные значения параметров вентиляционного потока.

### Введение

Искусственная вентиляция легких (ИВЛ) – жизненно важная медицинская технология, используемая при различных патологических состояниях, сопровождающихся дыхательной недостаточностью. Эффективность ИВЛ напрямую зависит от правильного выбора параметров вентиляции, которые должны соответствовать индивидуальным особенностям пациента и характеру его заболевания [1].

Традиционные подходы к настройке параметров ИВЛ основаны на стандартизированных протоколах, которые не всегда учитывают индивидуальные особенности пациентов. Это может приводить к развитию таких осложнений, как баротравма, волютравма, ателектравма и биотравма [2]. Кроме того, существует проблема очень большого числа заболеваний, при которых требуется использование

✉ А.В. Крянев: AVKryanov@mephi.ru

Поступила в редакцию: 29.09.2025

После доработки: 27.10.2025

Принята к публикации: 05.11.2025

EDN PQVMTB

ИВЛ, и для каждого диагноза оптимальная программа управления режимами ИВЛ может существенно различаться [3].

Искусственные нейронные сети в последние годы находят широкое применение в медицине. Так нейронные сети активно применяются для анализа медицинских изображений с целью диагностики различных заболеваний [4], помогают разрабатывать индивидуальные планы лечения, учитывая особенности каждого пациента [5] и решения таких различных задач обработки медицинской информации [6], как заполнение и ведение медицинской документации, анализ генетических данных и прогнозирование эпидемиологических вспышек.

С развитием цифровой медицины и накоплением больших массивов клинических данных появилась возможность разработки более совершенных методов персонализации параметров ИВЛ. В данной статье предлагаются схема интерполяции оптимальных значений параметров вентиляционного потока на основе искусственных нейронных сетей и вторая схема, основанная на разрабатываемом в МИФИ математическом аппарате метрического анализа [7–11], позволяющая адаптировать параметры вентиляции к индивидуальным потребностям конкретного пациента.

### **Анализ применения нейросетевых технологий в научной литературе**

**Примеры нейросетевой интерполяции в медицинских публикациях.** В работе [12] предложен метод интерполяции медицинских изображений с использованием рекуррентных нейронных сетей с нечеткой логикой второго типа (RT2FNN). Данный подход демонстрирует превосходство над традиционными методами интерполяции. Метод успешно применяется для преобразования 2D-изображений в 3D-реконструкции в различных областях медицинской визуализации: МРТ головного мозга, КТ брюшной полости и нанотомографии.

В исследовании [13] предложена архитектура искусственной нейронной сети для решения задачи построения интерполяционных формул для удвоения размера изображений. Обученная модель получает в качестве аргумента матрицу размера  $4 \times 4$ , а результатом работы является интерполяционная формула, представленная в виде весового вектора для четырех точек. Сравнительный анализ показал, что предложенный подход имеет лучшее качество интерполяции по сравнению с методами New Edge-Directed Interpolation и Directional Cubic Convolution Interpolation.

В работе [14] нейронная сеть, разработанная для интерполяции видеокадров, применяется для улучшения томографических изображений across different length scales. Метод демонстрирует эффективность в различных областях:

- исследование морфологии напечатанных сетей графеновых наноллистов;
- магнитно-резонансная томография головного мозга человека;
- рентгеновская компьютерная томография брюшной полости.

Данный подход позволяет достичь изотропного разрешения вокселей и сохранить информационное содержание при сокращении времени acquisition.

**Анализ существующих подходов и методов в области машинного обучения к управлению аппаратами искусственной вентиляции легких.** В статье [15] рассматривается нейронная сеть с прямым распространением сигнала (FFNN) для подбора эффективных параметров управления аппаратом ИВЛ, для больных с хронической обструктивной болезнью легких и пневмонией. В качестве исходных данных использовались данные мониторинга аппаратов ИВЛ с неназванного госпиталя в Тайване. FFNN классифицировала пациентов по трем состояниям и подбирала контрольные параметры вентилятора (дыхательный объем, частота дыхания, соотношение вдох/выдох) на основе диагностированного состояния. Для проверки работоспособности модели авторами был разработан имитатор в среде Simulink.

В работе [16] рассматривались пациенты с острыми респираторными расстройствами, требующими механической вентиляции в отделении интенсивной терапии. Исследование представляет алгоритм VentAI, который с помощью обучения с подкреплением динамически оптимизирует параметры ИВЛ для критически больных пациентов, используя показатели смертности в качестве оптимизационной метрики. Использовался алгоритм обучения с подкреплением (Reinforcement Learning, RL) на основе Q-learning с применением k-means кластеризации для выявления групп состояний пациентов и марковский процесс принятия решений (MDP) с состоянием, действием, наградой и переходом состояний.

Данные для обучения и валидации модели были взяты из базы Medical Information Mart for Intensive Care III (MIMIC-III), а также датасета eICU Collaborative Research Database v2.0.

В статье [17] описано применение искусственного легкого для получения синтетических данных на основе манипуляций с параметрами сопротивления и эластичности легкого. Исследователи тестировали девять различных комбинаций состояний этих параметров для создания датасета. Используется рекуррентная нейронная сеть (RNN) типа Long Short-Term Memory (LSTM). LSTM выбрана для работы с временными рядами, так как она способна учитывать долгосрочные зависимости в последовательностях данных, что критично для моделирования дыхательных циклов. Нейросеть использовалась для предсказания давления в дыхательном контуре и обучалась на минимизацию абсолютного среднего отклонения (MAE) от данных, полученных на искусственном легком.

В работе [18] рассматривались критически больные пациенты в отделении интенсивной терапии с дыхательной недостаточностью, требующие искусственной вентиляции легких. Основное внимание уделяется асинхрониям – нарушениям синхронизации между дыхательными усилиями пациента и работой аппарата ИВЛ. Используется модифицированная U-Net архитектура, адаптированная для обработки одномерных сигналов (временных рядов), для сегментации временных меток начала и конца вдоха пациента.

### Математическая постановка задачи интерполяции

Формализация задачи многомерной интерполяции. Задача интерполяции оптимальных значений параметров вентиляционного потока при ИВЛ формализуется как проблема многомерной нелинейной регрессии. Математически это может быть представлено как восстановление неизвестной функции  $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$  по конечному набору наблюдений:

$$\bar{y} = f(\bar{x}) + \epsilon,$$

где  $\bar{x} = (x_1, x_2, \dots, x_n)^T \in \mathbb{R}^n$  – вектор показателей пациента;  $\bar{y} = (y_1, y_2, \dots, y_m)^T \in \mathbb{R}^m$  – вектор оптимальных параметров ИВЛ;  $\epsilon$  – случайная ошибка измерения.

### Формализация параметров пациента

Входной вектор  $\bar{x}$  включает группы параметров.

1. Антропометрические данные:

$$\text{должная масса тела } m_{\text{долж}} = \frac{50 + 0.91 \times (h - 152.4)}{0.1}, \text{ где } h - \text{рост, см;}$$

$$\text{избыточная масса тела } m_{\text{изб}} = m_{\text{факт}} - m_{\text{долж}}.$$

2. Показатели дыхательной системы:

$$\text{должная торакопьюмональная растяжимость } C_{\text{долж}} = 0.1 \times m_{\text{долж}};$$

$$\text{должное сопротивление дыхательных путей } R_{\text{долж}} = 0.03 \times m_{\text{долж}}.$$

3. Газообменные параметры:

отношение парциального давления кислорода в артериальной крови к фракции кислорода во вдыхаемой смеси –  $P_{aO_2}/F_{iO_2}$ ;

парциальное давление углекислого газа в артериальной крови –  $P_{aCO_2}$ ;

водородный показатель артериальной крови – pH;

насыщение гемоглобина кислородом –  $SpO_2$ .

Выходные параметры ИВЛ. Выходной вектор  $\bar{y}$  содержит оптимизируемые параметры вентиляции:

$$\bar{y} = (V_t, f, PEEP, FiO_2, T_i, Flow)_{\text{норм}},$$

где  $V_t$  – дыхательный объем, мл;  $f$  – частота дыхания, вдохов/мин;  $PEEP$  – положительное давление в конце выдоха, см. вод. ст.;  $FiO_2$  – фракция кислорода во вдыхаемой смеси, %;  $T_i$  – время вдоха, с;  $Flow$  – скорость потока газа на вдохе, л/мин.

Далее рассматриваются нейросетевые подходы к интерполяции параметров ИВЛ.

Архитектура нейронной сети для интерполяции. Для решения задачи интерполяции параметров ИВЛ предлагается использовать многослойный перцептрон (MLP) иначе называемый сетью прямого распространения (FFNN) с  $L$  скрытыми слоями. Архитектура сети описывается следующими уравнениями:

$$\begin{aligned}\bar{z}^{(0)} &= \bar{x}, \\ \bar{a}^{(l)} &= W^{(l)}\bar{z}^{(l-1)} + \bar{b}^{(l)}, \quad l=1, \dots, L, \\ \bar{z}^{(l)} &= \sigma(\bar{a}^{(l)}), \quad l=1, \dots, L, \\ \bar{y} &= W^{(L+1)}\bar{z}^{(L)} + \bar{b}^{(L+1)},\end{aligned}\tag{1}$$

где  $W^{(l)}$  – матрица весового слоя;  $\bar{b}^{(l)}$   $l$  – вектор смещений  $l$ -го слоя;  $\sigma$  – функция активации (ReLU, th и др.).

Функция потерь и регуляризация. Для обучения нейронной сети используется функционал качества, включающий функцию потерь и регуляризационные слагаемые:

$$J(\theta) = \frac{1}{N} \sum_{i=1}^N L(\bar{y}_i, f(\bar{x}_i; \theta)) + \lambda R(\theta),\tag{2}$$

где  $L(\bar{y}, \hat{y})$  – функция потерь (среднеквадратичная ошибка);  $L(\bar{y}, \hat{y}) = \frac{1}{m} \sum_{j=1}^m (y_j - \hat{y}_j)$ ;  $R(\theta)$  – регуляризатор;  $\lambda$  – коэффициент регуляризации.

Методы оптимизации и борьбы с переобучением. Для обучения нейронной сети применяется адаптивный моментный метод (Adam), который сочетает преимущества алгоритмов RMSProp и Momentum:

$$\begin{aligned}m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t, \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t}, \\ \theta_{t+1} &= \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon},\end{aligned}\tag{3}$$

где  $g_t$  – градиент функции потерь на шаге  $t$ ;  $\beta_1, \beta_2$  – параметры экспоненциального затухания;  $\alpha$  – скорость обучения;  $\epsilon$  – малая константа для обеспечения численной устойчивости.

Для борьбы с переобучением используются следующие методы:

1. Регуляризация методом исключения. На этапе обучения каждый нейрон исключается с вероятностью  $p$ .
2. Пакетная нормализация: нормализация активаций внутри мини-батча.
3. Ранняя остановка: прекращение обучения при ухудшении качества на валидационной выборке
4. Интеграция с системами мониторинга. Разработка систем реального времени для адаптации

параметров ИВЛ на основе непрерывного анализа данных мониторинга. Это позволит динамически менять параметры вентиляции в соответствии с изменяющимся состоянием пациента.

5. Обучение с подкреплением. Использование методов глубокого обучения с подкреплением для непрерывного улучшения алгоритмов без необходимости переобучения на новых данных. Это особенно важно в условиях меняющейся патологии пациентов.

6. Мультимодальные модели. Разработка моделей, интегрирующих данные визуализации (КТ, МРТ) с клиническими и лабораторными параметрами для более точной настройки ИВЛ. Это позволит учитывать больше факторов при определении оптимальных параметров вентиляции.

7. Байесовские нейронные сети. Внедрение байесовских подходов для оценки неопределенности предсказаний:

$$p(\theta|\mathcal{D}) = \frac{p(\mathcal{D}|\theta)p(\theta)}{p(\mathcal{D})},$$

где  $p(\theta|\mathcal{D})$  – апостериорное распределение параметров;  $p(\mathcal{D}|\theta)$  – функция правдоподобия;  $p(\theta)$  – априорное распределение параметров;  $p(\mathcal{D})$  – evidence.

8. Трансферное обучение. Использование методов трансферного обучения для адаптации моделей, обученных на больших наборах данных, для конкретных медицинских учреждений:

$$\theta_{target} = \arg \min_{\theta} \left[ L_{target}(\theta) + \lambda \cdot \|\theta - \theta_{source}\|_2^2 \right]. \quad (5)$$

Для оптимальной интерполяции значений параметров вентиляционного потока в зависимости от текущих показателей состояния пациента можно использовать метод, основанный на метрическом анализе и разработанный в МИФИ для восстановления значений функции одной или многих переменных [7].

Для функциональной зависимости  $Y = F(X_1, \dots, X_m) = F(\vec{X})$ , где функция  $F(\vec{X})$  неизвестна, должно быть восстановлено значение этой функции либо в одной точке  $\vec{X}^*$ , либо в наборе заданных точек на основе известных значений функции  $\vec{Y} = (Y_1, \dots, Y_n)^T$  в фиксированных точках  $\vec{X}_k = (X_{k1}, \dots, X_{km})^T$ .

Оптимальное значение  $Y^*$  в точке  $\vec{X}^*$  определяется равенством

$$Y^* = \frac{(W^{-1}\vec{Y}, \vec{1})}{(W^{-1}\vec{1}, \vec{1})}. \quad (6)$$

Матрица метрической неопределенности  $W$  определяется формулой

$$W = \begin{pmatrix} \rho^2(\vec{X}_1, \vec{X}^*)\bar{\omega} & (\vec{X}_1, \vec{X}_2)\bar{\omega} & \dots & (\vec{X}_1, \vec{X}_n)\bar{\omega} \\ (\vec{X}_2, \vec{X}_1)\bar{\omega} & \rho^2(\vec{X}_2, \vec{X}^*)\bar{\omega} & \dots & (\vec{X}_2, \vec{X}_n)\bar{\omega} \\ \dots & \dots & \dots & \dots \\ (\vec{X}_n, \vec{X}_2)\bar{\omega} & (\vec{X}_n, \vec{X}_2)\bar{\omega} & \dots & \rho^2(\vec{X}_n, \vec{X}^*)\bar{\omega} \end{pmatrix}, \quad (7)$$

где

$$\rho^2(\vec{X}_1, \vec{X}^*)\bar{\omega} = \sum_{k=1}^m \omega_k (X_{1k} - X_k^*)^2, \quad (8)$$

$$(\bar{X}_i, \bar{X}_j) \bar{\omega} = \sum_{k=1}^m \omega_k (X_{ik} - X_k^*) \cdot (X_{jk} - X_k^*), \quad i, j = 1, \dots, n. \quad (9)$$

Оптимальные значения весов  $\omega_k$ ,  $k = 1, \dots, m$  вычисляются на этапе обучения с использованием таблицы полученных ранее значений параметров вентиляционного потока.

Метод, основанный на метрическом анализе, позволяет в режиме on line обучать или переобучать систему выбора оптимальных значений вентиляционного потока в динамическом режиме подключения пациента к аппарату искусственной вентиляции легких.

## Заключение

Представленный математический аппарат позволяет формализовать задачу интерполяции оптимальных параметров ИВЛ как проблему многомерной нелинейной регрессии. Использование искусственных нейронных сетей и схем метрического анализа обеспечивает возможность наиболее точной аппроксимации сложных нелинейных зависимостей между показателями текущего состояния конкретного пациента и оптимальными значениями параметров вентиляционного потока.

Нейросетевые подходы демонстрируют высокую эффективность в различных областях медицины, включая обработку медицинских изображений, диагностику заболеваний и персонализацию лечения. Дальнейшее развитие метода связано с внедрением байесовских подходов для оценки uncertainty, методов трансферного обучения для учета различных диагнозов и разработкой эффективных алгоритмов оптимизации для работы с высокоразмерными данными.

Внедрение таких систем в клиническую практику требует решения ряда проблем, связанных с накоплением и стандартизацией данных, валидацией алгоритмов и интеграцией с существующими медицинскими системами. Однако потенциал применения нейросетевых методов и методов метрического анализа для персонализации оптимальных значений параметров ИВЛ велик и может привести к значительному повышению эффективности лечения пациентов с дыхательной недостаточностью.

## Финансирование

Исследование выполнено при поддержке гранта Российского научного фонда № 25-21-20143, <https://rscf.ru/project/25-21-20143/>.

## Конфликт интересов

Конфликт интересов отсутствует.

## Вклад авторов

*С.Г. Климанов* – постановка задачи, выбор методов исследования, разработка математической модели, подготовка текста статьи, участие в проведении исследования и обсуждении результатов, подготовка текста статьи.

*А.В. Крянев* – постановка задачи, выбор методов исследования, разработка математической модели, подготовка текста статьи, участие в проведении исследования и обсуждении результатов, подготовка текста статьи.

*А.А. Котляров* – постановка задачи, выбор методов исследования, постановка эксперимента, участие в проведении исследования и обсуждении результатов.

*Д.С. Смирнов* – участие в подготовке литературного обзора, разработка математической модели, подготовка текста статьи.

*И.В. Сопенко* – участие в проведении исследования и обсуждении результатов.

*В.А. Трикозова* – участие в проведении исследования и обсуждении результатов.

*Д.Д. Царева* – участие в проведении исследования и обсуждении результатов.

## Список литературы

1. Чурсин В.В. Искусственная вентиляция легких: Учебно-методическое пособие. Алматы, 2008. 55 с. ISBN 9965-874-64-6.
2. Кузьков В.В., Суборов Е.В., Фот Е.В., Родионова Л.Н., Соколова М.М., Лебединский К.М., Киров М.Ю. Послеоперационные дыхательные осложнения и ОРДС легче предупредить, чем лечить // Анестезиология и реаниматология, 2016. № 61(6). С. 461–468.
3. Патент RU2003121722A. Способ проведения длительной искусственной вентиляции легких. Google Patents, 2019. <https://patents.google.com/patent/RU2003121722A/ru>.
4. Li M., Jiang Y., Zhang Y., Zhu H. Medical image analysis using deep learning algorithms // *Frontiers in Public Health*, 2023. V. 11. 1273253. DOI: 10.3389/fpubh.2023.1273253.
5. Zhang L., Zhu E., Shi J., Wu X., Cao S., Huang S., Ai Z., Su J. Individualized treatment recommendations for patients with locally advanced head and neck squamous cell carcinoma utilizing deep learning // *Front. Med.*, 2025. V. 11. 1478842. DOI: 10.3389/fmed.2024.1478842.
6. Perkins S.W., Muste J.C., Alam T., Singh R.P. Improving Clinical Documentation with Artificial Intelligence: A Systematic Review // *Perspectives in health information management*, 2024. V. 21(2). Ld. PMID: PMC11605373.
7. Крянев А.В., Лукин Г.В., Удумын Д.К. Метрический анализ и обработка данных. М.: Физматлит, 2012. 308 с.
8. Kryanev A.V., Udumyan D.K. Metric analysis, properties and applications as a tool for interpolation // *International Journal of Mathematical Analysis*, 2014. V. 8 (45). P. 2221–2228. DOI: 10.12988/ijma.2014.48252.
9. Kryanev A.V., Udumyan D. K. Metric Analysis, Properties and Applications as a Tool for Forecasting // *International Journal of Mathematical Analysis*, 2014. V. 8. № 60. P. 2971–2978. DOI: 10.12988/ijma.2014.411341.
10. Ivanov V.V. Kryanev A.V., Udumyan D.K., Lukin G.V. Metric Analysis Approach for Interpolation and Forecasting of Time Processes // *Applied Mathematical Sciences*, 2014. V. 8. № 22. P. 1053–1060. DOI: 10.12988/ams.2014.312727.
11. Климанов С.Г., Котляров А.А., Крянев А.В., др. Сравнение методов выявления аномальных выбросов в исходных данных и их применение при обработке данных искусственной вентиляции легких // *Вестник НИЯУ МИФИ*, 2025. Т. 14(1). С. 37–49. DOI: 10.26583/vestnik.2025.1.4.
12. Tavoosi J., Zhang Ch., Mohammadzadeh A., Mobayen S., Mosavi A.H. Medical Image Interpolation Using Recurrent Type-2 Fuzzy Neural Networks // *Frontiers in Neuroinformatics*, 2021. V. 15. 667375. DOI: 10.3389/fninf.2021.667375.
13. Ваганов С.Е. Адаптивный нейросетевой метод построения интерполяционной формулы для удвоения размера изображения // *Компьютерная оптика*, 2019. Т. 43. № 4. С. 627–631. DOI: 10.18287/2412-6179-2019-43-4-627-631.
14. Gambini L., Gabbett C., Doolan L., Jones L., et al. Video frame interpolation neural network for 3D tomography across different length scales // *Nature Communications*, 2024. V. 15 (1). 7962. DOI: 10.1038/s41467-024-52260-2.
15. Hariharan S., Karnan H., Maheswari D.U. Automated mechanical ventilator design and analysis using neural network // *Scientific Reports*, 2025. V. 15. 3212. DOI: 10.1038/s41598-025-87946-0.
16. Peine A., Hallawa A., Bickenbach J., et al. Development and validation of a reinforcement learning algorithm to dynamically optimize mechanical ventilation in critical care // *NPJ Digital Medicine*, 2021. V. 4 (1). DOI: 10.1038/s41746-021-00388-6.
17. Diao S. Changsong W., Junyu W., Yizhou Li. Ventilator pressure prediction using recurrent neural network. DOI: 10.48550/arXiv.2410.06552.
18. Bakkes T., Diepen A. van, Bie A.De., Montenij L. Automated detection and classification of patient – ventilator asynchrony by means of machine learning and simulated data // *Computer Methods and Programs in Biomedicine*, 2023. V. 230 (6). 107333. DOI: 10.1016/j.cmpb.2022.107333.

## Two schemes for interpolation of optimal values of ventilation flow parameters depending on the values of patient indicators during artificial ventilation of the lungs

S. G. Klimanov<sup>1</sup>, A. V. Kryanev<sup>1,2,✉</sup>, A. A. Kotlyarov<sup>3</sup>, D. S. Smirnov<sup>1</sup>, I. V. Sopenko<sup>3</sup>, V. A. Trikozova<sup>1</sup>, D. D. Tsareva<sup>1</sup>

<sup>1</sup>National Research Nuclear University «MEPhI», Moscow, 115409, Russia

<sup>2</sup>Joint Institute for Nuclear Research, Dubna, 141980, Russia

<sup>3</sup>Obninsk Institute for Nuclear Power Engineering, Obninsk, Kaluga region, 249039, Russia

✉ AVKryanev@mephi.ru

Received September 29, 2025; revised October 27, 2025; accepted November 05, 2025

This article, based on a database of initial data on successful patient treatment, proposes two schemes for interpolating optimal ventilation flow parameter values during artificial lung ventilation (ALV) for a given patient. At the mathematical level, selecting optimal ventilation flow parameter values based on the patient's current condition is a task of multivariate nonlinear regression analysis. The first scheme is based on the mathematical apparatus of artificial neural networks. The second scheme is based on the mathematical apparatus of metric analysis, developed at the Department of Applied Mathematics at MEPhI and currently used in mathematical data processing and optimization problems in various applied fields. The implementation of both schemes allows for the use of accumulated data on the successful treatment of patients with similar lung diseases on ventilators for the specific patient in question. Both schemes allow for the adaptation of optimal ventilation flow parameter values to the patient's current condition during treatment. In the future, it is planned to jointly use these two interpolation schemes to obtain a more accurate and reliable final result for solving the above-mentioned optimal interpolation problem.

**Keywords:** artificial ventilation of the lungs, patient indications, interpolation, optimal values of ventilation flow parameters.

### References

1. Chursin V.V. *Iskusstvennaya ventilyaciya lyogkih: Uchebno-metodicheskoe posobie*. [Artificial ventilation of the lungs: Textbook and methodological manual]. Almaty, 2008. 55 p. ISBN 9965-874-64-6.
2. Kuzkov V.V., Suborov E.V., Fot E.V., Rodionova L.N., Sokolova M.M., Lebedinskij K.M., Kirov M.Yu. *Posle-operacionnye dyhatel'nye oslozhneniya i ORDS legche predupredit', chem lechit'* [Post-operative respiratory complications and ARDS are easier to prevent than to treat]. *Anesteziologiya i reanimatologiya*, 2016. No. 61(6). Pp. 461–468 (in Russian).
3. Patent RU2003121722A. *Sposob provedeniya dlitel'noj iskusstvennoj ventilyacii legkih* [Method for Performing Long-Term Artificial Lung Ventilation]. Google Patents. 2019. <https://patents.google.com/patent/RU2003121722A/ru>.
4. Li M., Jiang Y., Zhang Y., Zhu H. Medical image analysis using deep learning algorithms. *Frontiers in Public Health*, 2023. Vol. 11. 1273253. DOI: 10.3389/fpubh.2023.1273253.
5. Zhang L., Zhu E., Shi J., Wu X., Cao S., Huang S., Ai Z., Su J. Individualized treatment recommendations for patients with locally advanced head and neck squamous cell carcinoma utilizing deep learning. *Front. Med.*, 2025. Vol. 11. 1478842. DOI: 10.3389/fmed.2024.1478842.
6. Perkins S.W., Muste J.C., Alam T., Singh R.P. Improving Clinical Documentation with Artificial Intelligence: A Systematic Review. *Perspectives in health information management*, 2024. Vol. 21(2). Ld. PMID: PMC11605373.
7. Kryanev A.V., Lukin G.V., Udumyan D.K. *Metricheskij analiz i obrabotka dannyh* [Metric analysis and data processing] Moscow, Fizmatlit Publ., 2012. 308 p.

8. *Kryanev A.V., Udumyan D.K.* Metric analysis, properties and applications as a tool for interpolation. *International Journal of Mathematical Analysis*, 2014. Vol. 8 (45). Pp. 2221–2228. DOI: 10.12988/ijma.2014.48252.
9. *Kryanev A.V., Udumyan D.K.* Metric Analysis, Properties and Applications as a Tool for Forecasting. *International Journal of Mathematical Analysis*, 2014. Vol. 8. No. 60. Pp. 2971–2978. DOI: 10.12988/ijma.2014.411341.
10. *Ivanov V.V., Kryanev A.V., Udumyan D.K., Lukin G.V.* Metric Analysis Approach for Interpolation and Forecasting of Time Processes. *Applied Mathematical Sciences*, 2014. Vol. 8. No. 22. Pp. 1053–1060. DOI: 10.12988/ams.2014.312727.
11. *Klimanov S.G., Kotlyarov A.A., Kryanev A.V., et al.* Sravnenie metodov vyyavleniya anomal'nyh vybrosov v iskhodnyh dannyh i ih primenenie pri obrabotke dannyh iskusstvennoj ventilyacii legkih [Comparison of methods for identifying abnormal outliers in source data and their application in processing artificial lung ventilation data]. *Vestnik NIYaU MIFI*, 2025. Vol. 14(1). Pp. 37–49 (in Russian). DOI: 10.26583/vestnik.2025.1.4.
12. *Tavoosi J., Zhang Ch., Mohammadzadeh A., Mobayen S., Mosavi A.H.* Medical Image Interpolation Using Recurrent Type-2 Fuzzy Neural Networks. *Frontiers in Neuroinformatics*, 2021. Vol. 15. 667375. DOI: 10.3389/fninf.2021.667375.
13. *Vaganov S.E.* Adaptivnyj nejrosetevoj metod postroeniya interpolyacionnoj formuly dlya udvoeniya razmera izobrazheniya [An adaptive neural network method for constructing an interpolation formula for doubling the image size]. *Komp'yuternaya optika*, 2019. Vol. 43. No. 4. Pp. 627–631. DOI: 10.18287/2412-6179-2019-43-4-627-631.
14. *Gambini L., Gabbett C., Doolan L., Jones L., et al.* Video frame interpolation neural network for 3D tomography across different length scales. *Nature Communications*, 2024. Vol. 15(1). 7962. DOI: 10.1038/s41467-024-52260-2.
15. *Hariharan S., Karnan H., Maheswari D.U.* Automated mechanical ventilator design and analysis using neural network. *Scientific Reports*, 2025. Vol. 15. 3212. DOI: 10.1038/s41598-025-87946-0.
16. *Peine A., Hallawa A., Bickenbach J., et al.* Development and validation of a reinforcement learning algorithm to dynamically optimize mechanical ventilation in critical care. *NPJ Digital Medicine*, 2021. Vol. 4 (1). DOI: 10.1038/s41746-021-00388-6.
17. *Diao S., Changsong W., Junyu W., Yizhou Li.* Ventilator pressure prediction using recurrent neural network. DOI: 10.48550/arXiv.2410.06552.
18. *Bakkes T., Diepen A. van, Bie A.De., Montenij L.* Automated detection and classification of patient – ventilator asynchrony by means of machine learning and simulated data. *Computer Methods and Programs in Biomedicine*, 2023. Vol. 230 (6). 107333. DOI: 10.1016/j.cmpb.2022.107333.