CC BY

http://dx.doi.org/10.35596/1729-7648-2026-24-5-101-109

УДК 004.942

ПРИМЕНЕНИЕ ГРАДИЕНТНОГО БУСТИНГА ДЛЯ ПРОГНОЗИРОВАНИЯ ИЗМЕНЕНИЯ НАПРЯЖЕННО-ДЕФОРМИРОВАННОГО СОСТОЯНИЯ ПОЯСНИЧНОГО ОТДЕЛА ПОЗВОНОЧНИКА ЧЕЛОВЕКА

Т. С. СЕМЕНЧЕНЯ

Гомельский государственный технический университет имени П. О. Сухого (Гомель, Республика Беларусь)

Аннотация. Классический конечно-элементный анализ поясничного отдела позвоночника жестко ограничен статической геометрией, получаемой в ходе компьютерной томографии в статическом положении пациента лежа. Прямой расчет напряженно-деформированного состояния для альтернативных физиологических поз в реальном времени невозможен из-за высокой вычислительной трудоемкости, отсутствия расчетных сеток для различных положений тела (наклоны к полу, боковые наклоны, удержание груза) и вариантов нагружения человека. В статье описывается разработка гибридного биомеханического подхода, который использует данные компьютерной томографии в покое для прогнозирования изменения напряженно-деформированного состояния в условиях изменения пространственного положения тела и вариантов нагружения. Для аппроксимации физических полей применены алгоритмы градиентного бустинга XGBoost и CatBoost. Предлагаемый подход позволяет выявлять зоны критической концентрации напряжений и деформаций при пространственном изменении положения тела и моделировать биомеханические состояния, недоступные для прямого численного анализа.

Ключевые слова: поясничный отдел позвоночника, метод конечных элементов, градиентный бустинг, CatBoost, XGBoost.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Для цитирования. Семенченя, Т. С. Применение градиентного бустинга для прогнозирования изменения напряженно-деформированного состояния поясничного отдела позвоночника человека / Т. С. Семенченя // Доклады БГУИР. 2026. Т. 24, № 5. С. 101–109. http://dx.doi.org/10.35596/1729-7648-2026-24-5-101-109.

APPLICATION OF GRADIENT BOOSTING TO PREDICT CHANGES IN THE STRESS-STRAIN STATE OF THE HUMAN LUMBAR SPINE

TATYANA SEMENCHENIA

Sukhoi State Technical University of Gomel (Gomel, Republic of Belarus)

Abstract. Conventional finite element analysis of the lumbar spine is strictly limited to the static geometry obtained via computed tomography with the patient in a static, supine position. Direct calculation of the stress-strain state for alternative physiological postures in real time is unfeasible due to high computational demands and the lack of computational meshes corresponding to various body positions (such as forward bending, lateral bending, or load-bearing) and loading scenarios. This article describes the development of a hybrid biomechanical approach that utilizes resting-state computed tomography data to predict changes in the stress-strain state resulting from variations in body position and loading conditions. Gradient boosting algorithms – specifically XGBoost and CatBoost – are employed to approximate the physical fields. The proposed approach enables the identification of zones with critical stress and strain concentrations during changes in body position and allows for the modeling of biomechanical states that are otherwise inaccessible to direct numerical analysis.

Keywords: lumbar spine, finite element method, gradient boosting, CatBoost, XGBoost.

Conflict of interests. The author declares that there is no conflict of interests.

For citation. Semenchenia T. (2026) Application of Gradient Boosting to Predict Changes in the Stress-Strain State of the Human Lumbar Spine. *Doklady BGUIR*. 24 (5), 101–109. http://dx.doi.org/10.35596/1729-7648-2026-24-5-101-109 (in Russian).

Введение

Заболевания и дегенеративно-дистрофические изменения поясничного отдела позвоночника прочно удерживают лидирующие позиции среди причин временной нетрудоспособности и инвалидности населения трудоспособного возраста во всем мире [1, 2]. Точная количественная оценка распределения напряженно-деформированного состояния (НДС) элементов позвоночно-двигательных сегментов критически важна для биомеханического анализа опорно-двигательного аппарата и планирования медицинских вмешательств [3, 4].

Современная биомеханика использует метод конечных элементов (МКЭ) как ключевой подход анализа распределения внутренних напряжений и деформаций. Однако МКЭ имеет фундаментальное ограничение: расчетная трехмерная геометрия строится по данным компьютерной томографии (КТ), которая выполняется исключительно в статическом положении пациента лежа [5].

В условиях реальной жизнедеятельности (наклоны, повороты, удержание и подъем тяжестей) биомеханическая картина радикально меняется. Прямой численный расчет НДС для множества альтернативных положений тела требует непрерывной перестройки сеточных моделей высокого порядка, что делает данный подход тяжело реализуемым. Для преодоления этого барьера привлекаются методы машинного обучения. Алгоритмы градиентного бустинга способны выступать в роли суррогатных моделей, принимая за основу базовую КТ-геометрию. Они аппроксимируют физические поля и прогнозируют НДС в режимах нагрузок, недоступных для прямого пошагового численного моделирования [6].

Цель исследований – разработка и верификация гибридного биомеханического подхода, интегрирующего методы конечно-элементного анализа и алгоритмы машинного обучения, для оперативного прогнозирования эволюции НДС поясничного отдела позвоночника в условиях изменения пространственного положения тела и вариантов нагружения. В отличие от классических статических моделей предлагаемая методология ориентирована на отслеживание динамического перераспределения механических напряжений и деформаций в позвонковых структурах и межпозвонковых дисках при различных положениях тела. Это открывает возможность персонализированного прогнозирования зон риска механического повреждения тканей опорно-двигательного аппарата в режимах, которые невозможно рассчитать напрямую.

Методика проведения исследований

Для реализации численного анализа и последующего оперативного прогнозирования биомеханического поведения поясничного отдела позвоночника была применена комплексная методика, сочетающая трехмерное конечно-элементное моделирование и суррогатное моделирование на основе алгоритмов машинного обучения. В качестве исходных данных использовались результаты КТ поясничного отдела позвоночника человека без выраженных костно-деструктивных изменений. Шаг сканирования составлял 1 мм.

Для анатомической сегментация КТ-данных и построения расчетной геометрии был разработан программный комплекс с привлечением инструментов нейросетевой архитектуры. Процесс подготовки модели включал следующие этапы:

– сегментация костных структур: автоматическое распознавание и генерация поверхностных полигональных сеток для тел позвонков;

– сегментация межпозвонковых дисков: автоматическое выделение анатомических областей хрящевой ткани в межпозвонковых дисках;

– объединение сгенерированных элементов в единую анатомическую модель (позвонки с дисками);

– оптимизация расчетной сетки: проведение изотропного сглаживания поверхностей и адаптивного упрощения (децимации) сетки для обеспечения стабильности и сходимости численного решения.

На основе анатомической сегментации КТ-данных была построена базовая трехмерная геометрия тел позвонков ($L1$–$L5$) и межпозвонковых дисков. Межпозвонковые диски были аппроксимированы как сплошные (монолитные) трехмерные тела без разделения на пульпозное ядро и фиброзное кольцо. В виде базового эффективного модуля упругости сплошного физиологически здорового диска принималось нормативное значение E = 42 МПа, что на порядок больше значений модулей упругости его отдельных компонентов [5, 7].

Тела позвонков моделировались как однородные твердые тела с физико-механическими свойствами кортикальной кости, без явного выделения губчатого вещества. Для имитации различных стадий дегенеративно-дистрофических изменений (снижения жесткости диска) в расчетный план закладывалось варьирование модуля упругости ткани диска в диапазоне от 20 до 42 МПа. Физико-механические свойства конечно-элементного моделирования представлены в табл. 1.

Таблица 1. Физико-механические характеристики конечно-элементного моделирования
Table 1. Physical and mechanical characteristics for finite element modeling

Анатомическая структура	Модуль упругости (Юнга) E, МПа	Коэффициент Пуассона ν
Тело позвонка ($L1$–$L5$)	12 000	0,30
Межпозвонковый диск (сплошной)	20–42	0,45

Взаимодействие на контактных границах «позвонок – диск» моделировалось с использованием условий непрерывного неразрывного соединения, полностью исключающих взаимное проскальзывание и раскрытие стыков под нагрузкой. Иные типы нелинейных контактов и связочный аппарат не учитывались.

Построение конечно-элементной сетки выполнялось на базе тетраэдральных элементов второго порядка. Базовый глобальный размер элемента составлял 4 мм. В зонах со сложной геометрической конфигурацией применялась процедура автоматического адаптивного измельчения, при которой минимальная длина ребер элементов локально уменьшалась до 0,46 мм. В исходной конфигурации конечно-элементная модель насчитывала 206 296 элементов и 363 148 узлов.

С целью подтверждения достоверности и устойчивости численного решения проводилось исследование сеточной сходимости методом последовательного уменьшения шага дискретизации. При уменьшении глобального размера элемента с 4 до 2 мм количество конечных элементов увеличивалось до 392 769. Относительное отклонение контролируемых параметров на сопоставляемых сетках составило около 1 %, что свидетельствует о достижении сеточной инвариантности и достаточной плотности разработанной конечно-элементной модели.

Граничные условия имитировали переход из одного положения в другое: нижняя замыкательная пластинка позвонка $L5$ жестко фиксировалась по всем степеням свободы, а к верхней границе $L1$ прикладывался вектор признаков

$$X = [F_z, M_x, M_y, M_z, E_{\text{диска}}], \tag{1}$$

где F_z – осевая компрессионная нагрузка, Н, учитывает вес верхней части тела, тонус околопозвоночных мышц и вес удерживаемых предметов; M_x – изгибающий момент, Н·мм, отвечает за наклон к полу ($+M_x$) или разгибание назад ($-M_x$); M_y – изгибающий момент, Н·мм, моделирует наклон туловища влево ($+M_y$) или вправо ($-M_y$); M_z – крутящий момент относительно вертикальной оси, Н·мм, имитирует осевое скручивание позвоночника вокруг своей оси; $E_{\text{диска}}$ – эффективный модуль упругости (Юнга) межпозвонкового диска, МПа, выступает в роли главного биомеханического дескриптора дегенеративно-дистрофических изменений (например, остеохондроза).

На рис. 1 представлена модель поясничного отдела позвоночника с примененными граничными условиями и напряжениями.

Для генерации обучающей выборки использовалось 10 различных моделей поясничного отдела позвоночника человека, для каждой из которых была сделана серия из 100 автоматизированных расчетных итераций в CAE-системе. Входные воздействия варьировались в следующих диапазонах:

– модуль упругости диска E – от 20 до 42 МПа;

– изгибающие моменты M_x – от минус 5000 до 5000 Н·мм и M_y – от минус 3500 до 4000 Н·мм; крутящий момент M_z – от минус 2000 до 5000 Н·мм;

– осевая компрессия F_z – от минус 2500 до минус 390 Н.

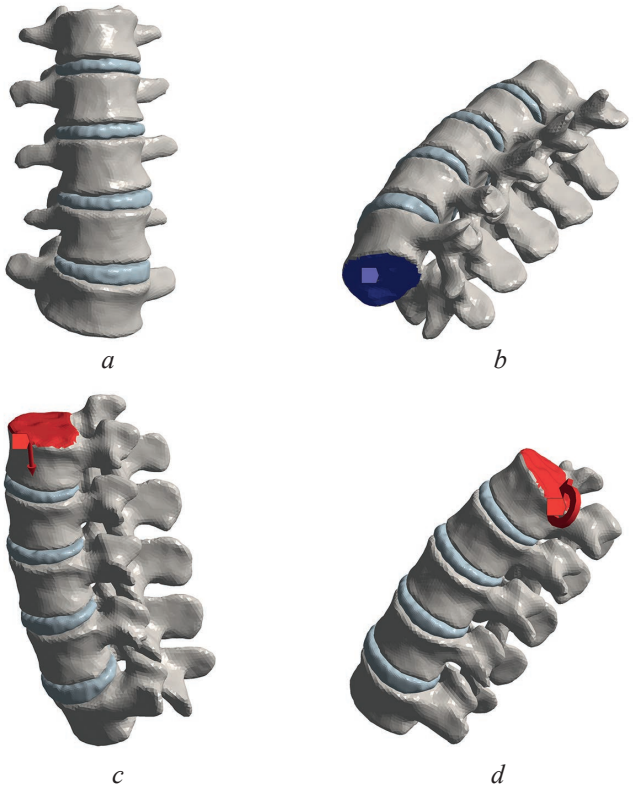


Рис. 1. Модель поясничного отдела позвоночника с примененными граничными условиями и напряжениями: *a* – геометрия; *b* – фиксация; *c* – нагрузка; *d* – крутящий момент
Fig. 1. Lumbar spine model with applied boundary conditions and stresses: *a* – geometry; *b* – fixation; *c* – load; *d* – torque

Для проверки обобщающей способности моделей использовался метод отложенной выборки. Тестовый набор был сформирован из четырех биомеханических сценариев, смоделированных на изолированной анатомической структуре и полностью исключенных из процесса обучения. С целью обеспечения воспроизводимости результатов расчеты проводились с фиксированной инициализацией генератора случайных чисел. Выходными данными (вектор ответов *Y*) выступали два ключевых биомеханических параметра, наиболее полно отражающих риск повреждения тканей под нагрузкой:

– максимальные эквивалентные напряжения по Мизесу σ_{max}, МПа;

– максимальные эквивалентные деформации ε_{max}, мм.

Для построения прогнозных суррогатных моделей выбирали два передовых алгоритма градиентного бустинга над решающими деревьями: XGBoost (Extreme Gradient Boosting) и CatBoost (Categorical Boosting) [8, 9]. Выбор данных алгоритмов обусловлен следующими научно-практическими факторами:

– высокая точность на табличных данных: градиентный бустинг применяется для работы с неоднородными табличными выборками малого и среднего объемов, значительно превосходя классические линейные модели и глубокие нейронные сети по скорости сходимости и устойчивости к переобучению;

– эффективная работа в условиях ограниченной выборки: оба алгоритма используют ансамблирование слабых учеников (деревьев решений) с последовательным исправлением ошибок предыдущих шагов, что минимизирует дисперсию прогноза на небольших массивах данных;

– устойчивость к мультиколлинеарности: входные биомеханические признаки (силы, моменты и жесткость) могут иметь скрытые взаимосвязи, однако древовидная структура базовых алгоритмов нечувствительна к масштабу и корреляции признаков.

Основное различие между алгоритмами – метод построения решающих деревьев:

– XGBoost строит асимметричные деревья, развивая их по принципу «лучший лист» (leaf-wise), обеспечивая максимальную гибкость и глубокую подстройку под нелинейные зависимости физических процессов;

– CatBoost использует симметричные (облигатные) деревья решений (depth-wise). В таких деревьях на каждом уровне применяется один и тот же критерий расщепления, что служит мощным встроенным механизмом регуляризации. Это делает данный алгоритм менее склонным к переобучению на малых выборках и позволяет ему сохранять высокую обобщающую способность, даже если параметры моделей использовались в базовой конфигурации без глубокой оптимизации.

Для обеспечения корректности сравнительной оценки алгоритмов обе модели обучались при одинаковых гиперпараметрах. Значения остальных параметров были выбраны в соответствии с технической документацией используемых программных пакетов и согласовывались с практикой решения аналогичных задач регрессии [10]. Параметры обучения суррогатных моделей представлены в табл. 2.

Таблица 2. Параметры обучения суррогатных моделей
Table 2. Training parameters of surrogate models

Параметр	Модель XGBoost	Модель CatBoost
Число деревьев	65	65
Максимальная глубина	5	5
Скорость обучения	0,1	0,1
Функция потерь	MSE	RMSE
*L*2-регуляризация	*reg_lambda* = 1,0	*l2_leaf_reg* = 3,0
*L*1-регуляризация	*reg_alpha* = 0	–
Схема ветвления	leaf-wise (асимметричная)	depth-wise (симметричная)

Результаты исследования

Проверка обученных суррогатных моделей выполнялась верификацией на тестовых сценариях, не участвовавших в обучении, и оценкой качества методом кросс-валидации. Для независимой верификации и оценки обобщающей способности суррогатных моделей использовалось четыре сценария, воспроизводящих сложные пространственные позы и комбинации нагрузок:

– сценарий 1: глубокий наклон вперед к полу из положения стоя, межпозвонковые диски в физиологической норме;

– сценарий 2: боковой наклон влево из положения сидя (рука вверх), начальная дегенерация межпозвонковых дисков;

– сценарий 3: боковой наклон туловища вправо, начальная дегенерация межпозвонковых дисков;

– сценарий 4: наклон держа вес (≈10 кг) в левой руке, межпозвонковые диски в физиологической норме.

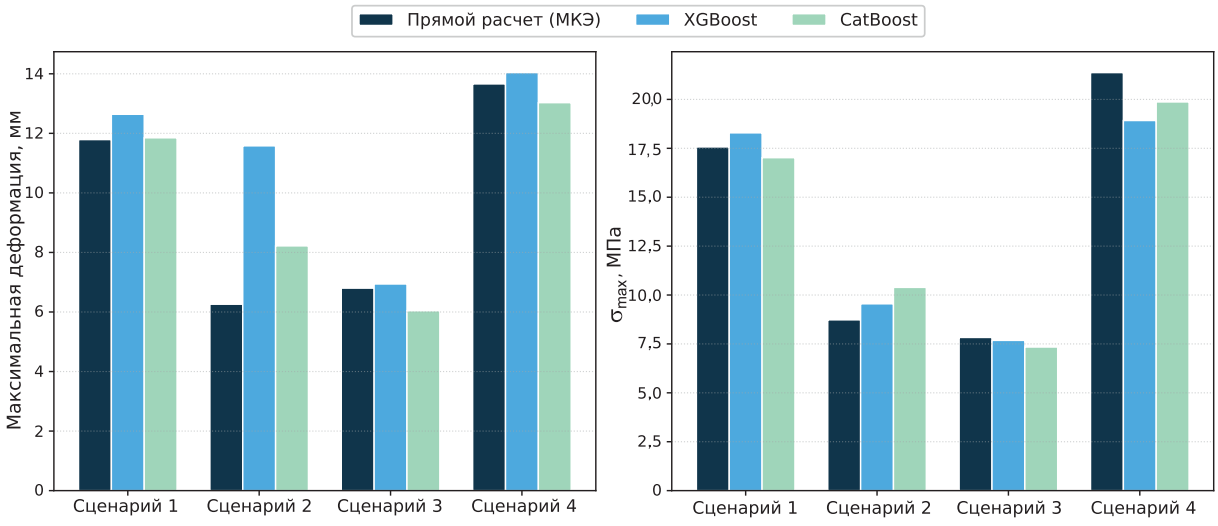
Физические параметры входных воздействий (вектор признаков X) приведены в табл. 3.

Таблица 3. Входные параметры расчетных биомеханических сценариев
Table 3. Input parameters for computational biomechanical scenarios

Сценарий	Модуль Юнга диска E, МПа	Изгибающий момент, Н·мм		Крутящий момент M_z, Н·мм	Осевая сила F_z, Н
		M_x	M_y		
1	42	4800	0	0	–1850
2	33	600	3200	800	–1150
3	33	0	–3300	0	–750
4	42	4300	1700	600	–2400

Сравнительный анализ моделей по максимальной деформации и максимальному эквивалентному напряжению

Программный расчет прогнозных значений максимальной деформации с использованием суррогатных моделей продемонстрировал качественные и количественные различия между применяемыми алгоритмами (рис. 2, *a*). В то же время анализ максимальных эквивалентных напряжений σ_{max} (рис. 2, *b*) по Мизесу позволил оценить прочностной отклик хрящевой ткани дисков для каждого тестового сценария.



a *b*

Рис. 2. Сравнительный анализ прогнозирования: *a* – максимальной деформации; *b* – максимального эквивалентного напряжения

Fig. 2. Comparative analysis of the prediction of: *a* – maximum deformation; *b* – maximum equivalent stress

Сравнительный анализ прогнозирования максимальной деформации показал высокую точность моделей машинного обучения при прогнозировании деформаций по сравнению с МКЭ-эталонами, при этом CatBoost продемонстрировал большую устойчивость. В сценарии 1 (глубокий наклон к полу) при КЭ-эталоне 11,79 мм модель XGBoost показала результат 12,64 мм (завышение на 7,2 %), а CatBoost – 11,85 мм, зафиксировав отклонение всего в 0,5 %. В условиях сценария 2 (боковой наклон влево, сидя) эталон МКЭ составил 6,26 мм – здесь алгоритм XGBoost продемонстрировал выраженное аппроксимационное перерегулирование в сочетанной позе, завысив деформационный критерий до 11,58 мм, тогда как алгоритм CatBoost проявил себя стабильнее, выдав прогноз 8,22 мм. Для сценария 3 (чистый боковой наклон вправо) при эталоне 6,80 мм алгоритм XGBoost зафиксировал значение 6,94 мм (+2,0 %), а CatBoost – 6,04 мм (отклонение 11,2 %). В сценарии 4 (наклон вперед с удержанием груза) МКЭ-эталон составил 13,66 мм, при этом прогноз XGBoost – 14,04 мм (+2,7 %), а CatBoost – 13,03 мм (–4,6 %).

По данным прямого численного расчета МКЭ, пиковые эквивалентные напряжения для статических сценариев 2 и 3 составляют 8,73 и 7,83 МПа соответственно. При глубоком наклоне к полу (сценарий 1) эталонное напряжение возрастает до 17,57 МПа, а в условиях интенсивного асимметричного нагружения с отягощением (сценарий 4) достигает максимума – 21,37 МПа.

Алгоритм XGBoost из-за асимметричного принципа ветвления деревьев решений продемонстрировал склонность к дискретной фиксации результатов на границах диапазонов. В сценарии 2 модель завысила прочностной критерий до 9,55 МПа, а под пиковой нагрузкой в сценарии 4, наоборот, занизила прогноз до 18,92 МПа (отклонение составило 11,4 %).

Алгоритм CatBoost показал высокую степень достоверности физического отклика по всем точкам интерполяции. Его предсказания для сценариев 1, 2, 3 и 4 составили 17,02, 10,39, 7,34 и 19,87 МПа соответственно. Отклонение от эталона МКЭ в большинстве точек не превышает 7,0 %. Использование регулярных симметричных деревьев решений послужило эффективным встроенным регуляризатором, позволившим CatBoost успешно сгладить локальные сеточные шумы малого тренировочного набора данных и точно воспроизвести непрерывную физическую поверхность отклика прочностных параметров даже в промежуточных координатах.

Оценка качества моделей

Оценка качества моделей проводилась методом пятикратной кросс-валидации. Для каждой целевой переменной рассчитывались среднеквадратичная ошибка RMSE, средняя абсолютная ошибка MAE и коэффициент детерминации RI. В табл. 4 приведены полученные значения метрик качества суррогатных моделей.

Таблица 4. Метрики качества суррогатных моделей
Table 4. Quality metrics of surrogate models

Целевой параметр	Модель	RMSE	MAE	*R*I
Максимальное напряжение, МПа	XGBoost	0,902	0,696	0,959
	CatBoost	0,961	0,743	0,953
Максимальная деформация, мм	XGBoost	0,990	0,731	0,964
	CatBoost	0,845	0,621	0,974

По результатам кросс-валидации обе модели показали сопоставимую точность. Алгоритм XGBoost незначительно превзошел CatBoost по точности прогнозирования максимального напряжения (RI = 0,959 против 0,953), тогда как CatBoost показал более высокую точность по деформации (RI = 0,974 против 0,964). Различие между алгоритмами проявляется преимущественно в характере поведения на отдельных точках: XGBoost демонстрирует склонность к смещению прогнозов вблизи границ обучающего диапазона, тогда как CatBoost обеспечивает более стабильное воспроизведение физического отклика.

Оценка относительной значимости входных факторов

Для раскрытия внутренней логики принятия решений алгоритмами проводился анализ относительного вклада входных признаков в формирование прогнозного биомеханического отклик-сигнала (рис. 3).

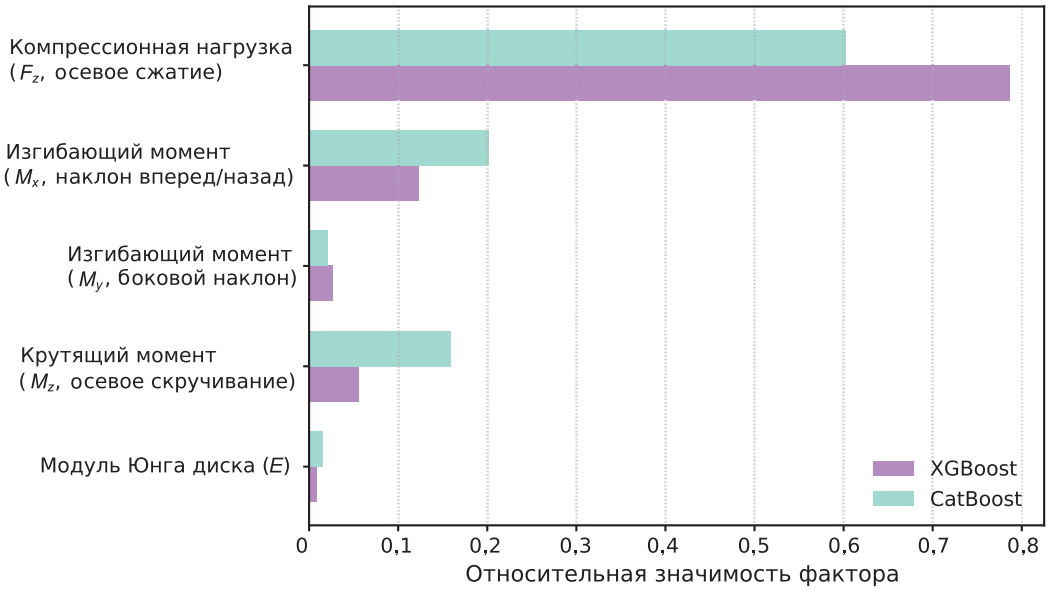


Рис. 3. Сравнительный анализ относительной значимости входных биомеханических признаков
Fig. 3. Comparative analysis of the relative importance of input biomechanical features

Оба алгоритма определили входную сжимающую силу F_z как доминирующий фактор. Однако в структуре XGBoost зафиксировано гипертрофированное смещение веса в сторону входа F_z (около 80 %) при игнорировании моментов M_x, M_y и M_z (суммарно – менее 15 %). Модель CatBoost продемонстрировала физически обоснованное и сбалансированное распределение значимости факторов при пространственном нагружении элементов позвоночника: вклад компрессионной нагрузки составил 58 %, изгибающего момента вперед/назад – 19 %, изгибающего момента бокового наклона – 5 %, крутящего момента – 16 %. Минимальный вклад модуля Юнга в обеих моделях (менее 2 %) объясняется тем, что вариация упругих свойств хряща оказывает локальное модулирующее действие преимущественно на выходные деформации, тогда как общий уровень напряжений зависит от внешнего силового вектора.

Заключение

1. Предложен гибридный подход, который успешно решает проблему «статичности» данных компьютерной томографии. Используя исходную геометрию, полученную в положении лежа, суррогатные модели позволяют прогнозировать напряженно-деформированное состояние для сложных физиологических поз (глубокие наклоны к полу, боковые наклоны, асимметричное удержание груза) и вариантов нагружения человека. Прямой расчет данных состояний методом конечных элементов затруднен в клинической практике из-за невозможности оперативного построения динамических расчетных сеток для каждого положения туловища стоя или сидя.

2. Проведена сравнительная оценка алгоритмов машинного обучения. Выявлено, что алгоритм XGBoost склонен к аппроксимационному перерегулированию в промежуточных точках деформирования. Алгоритм CatBoost за счет использования регулярных симметричных деревьев решений обеспечивает физически непрерывную поверхность отклика и демонстрирует высокую точность интерполяции.

Список литературы

1. Гусева, В. Р. Дегенеративно-дистрофические заболевания позвоночника, патогенез, клинические проявления, диагностика, лечение / В. Р. Гусева, В. В. Никитина // Флагман науки. 2023. С. 55–64.
2. Automatic Generation of Subject-Specific Finite Element Models of the Spine from Magnetic Resonance Images / J. Kok [et al.] // Frontiers in Bioengineering and Biotechnology. 2023. Vol. 11.
3. Напряженно-деформированное состояние поясничного отдела позвоночника в III стадии дегенеративного процесса / Е. Л. Цитко [и др.] // Мультидисциплинарный подход к диагностике и лечению коморбидной патологии: сб. науч. ст. Респуб. науч.-практ. конф. с междунар. участием, Гомель, 29–30 нояб. 2018 г. Гомель: Гомельск. гос. мед. ун-т, 2018. С. 506–509.
4. Kurachka, K. Automation of Primary Diagnostics of Diseases of the Human Lumbar Spine Using Intelligent Analysis of CT Images / K. Kurachka, X. Wang // Open Semantic Technologies for Intelligent Systems: Research Papers Collection. 2025. Iss. 9. P. 355–360.
5. Семенченя, Т. С. Математическая модель напряженно-деформированного состояния поясничного отдела позвоночника человека на основе анализа КТ-изображений / Т. С. Семенченя, К. С. Курочка // Информационные технологии и системы: материалы Междунар. науч. конф., Минск, 19 нояб. 2025 г. Минск: Белор. гос. ун-т информ. и радиоэлек., 2025. С. 177–178.
6. Developing of a Mathematical Model to Perform Measurements of Axial Vertebral Rotation on Computer-Aided and Automated Diagnosis Systems, Using Raimondi's Method / J. Hurtado-Aviles [et al.] // Radiology Research and Practice. 2021. Vol. 1. P. 55–64.
7. Effective Modulus of the Human Intervertebral Disc and Its Effect on Vertebral Bone Stress / H. Yang [et al.] // Journal of Biomechanics. 2016. Vol. 49. P. 1134–1140.
8. Чумаченко, Е. Н. Расчет напряженно-деформированного состояния двигательного сегмента позвоночника при нагрузках / Е. Н. Чумаченко, И. В Логашина // Авиакосмическая и экологическая медицина. 2014. Т. 48, № 5. С. 51–57.
9. Массарон, Л. Машинное обучение на табличных данных: XGBoost, глубокое обучение и ИИ / Л. Массарон, М. Райан. СПб.: Питер, 2026.
10. Probst, P. Tunability: Importance of Hyperparameters of Machine Learning Algorithms / P. Probst, A.-L. Boulesteix, B. Bischl // Journal of Machine Learning Research. 2019. Vol. 20, No 53. P. 1–32.

Поступила 04.08.2026 Принята в печать 08.09.2026

References

1. Guseva V. R., Nikitina V. V. (2023) Degenerative-Dystrophic Diseases of the Spine, Pathogenesis, Clinical Manifestations, Diagnosis, Treatment. *Flagship of Science*. 55–64 (in Russian).
2. Kok J., Shcherbakova Y. M., Schlosser T. P., Seevinck P. R., Velden T. A., Castelein R. M., et al. (2023) Automatic Generation of Subject-Specific Finite Element Models of the Spine from Magnetic Resonance Images. *Frontiers in Bioengineering and Biotechnology*. 11.
3. Tsitko E. L., Smeyanovich A. F., Astapovich E. S., Tsitko E. V. (2018) Stress-Strain State of the Lumbar Spine at Stage III of the Degenerative Process. *Multidisciplinary Approach to the Diagnosis and Treatment of Comorbid Pathology, Collection of Scientific Papers from the Republican Scientific and Practical Conference with International Participation, Gomel, Nov. 29–30*. Gomel, Gomel State Medical University. 506–509 (in Russian).

4. Kurachka K., Wang X. (2025) Automation of Primary Diagnostics of Diseases of the Human Lumbar Spine Using Intelligent Analysis of CT Images. *Open Semantic Technologies for Intelligent Systems, Research Papers Collection*. (9). 355–360.
5. Semenchenya T. S., Kurochka K. S. (2025) Mathematical Model of the Stress-Strain State of the Human Lumbar Spine Based on the Analysis of CT Images. *Information Technologies and Systems, Proceedings of the International Scientific Conference, Minsk, Nov. 19*. Minsk, Belarusian State University of Informatics and Radioelectronics. 177–178 (in Russian).
6. Hurtado-Aviles J., Roca-Gonzalez J., Kurochka K. S., Manuel Sanz-Mengibar J., Santonja-Medina F. (2021) Developing of a Mathematical Model to Perform Measurements of Axial Vertebral Rotation on Computer-Aided and Automated Diagnosis Systems, Using Raimondi's Method. *Radiology Research and Practice*. 1, 55–64.
7. Yang H., Jekir M. G., Davis M. W., Keaveny T. M. (2016) Effective Modulus of the Human Intervertebral Disc and Its Effect on Vertebral Bone Stress. *Journal of Biomechanics*. 49, 1134–1140.
8. Chumachenko E. N., Logashina I. V. (2014) Calculation of the Stress-Strain State of the Spinal Motion Segment Under Loads. *Aerospace and Environmental Medicine*. 48 (5), 51–57 (in Russian).
9. Massaron L., Ryan M. (2026) *Machine Learning on Tabular Data: XGBoost, Deep Learning, and AI*. Saint Petersburg, Piter Publ. (in Russian).
10. Probst P., Boulesteix A.-L., Bischl B. (2019) Tunability: Importance of Hyperparameters of Machine Learning Algorithms. *Journal of Machine Learning Research*. 20 (53), 1–32.

Received: 4 August 2026 Accepted: 8 September 2026

Сведения об авторе

Семенченя Т. С., асп., ст. преп. каф. информационных технологий, Гомельский государственный технический университет имени П. О. Сухого

Адрес для корреспонденции

246746, Республика Беларусь,
Гомель, просп. Октября, 48
Гомельский государственный
технический университет имени П. О. Сухого
Тел.: +375 25 538-03-71
E-mail: levts@gstu.by
Семенченя Татьяна Сергеевна

Information about the author

Semenchenia T., Postgraduate, Senior Lecturer at the Department of Information Technology, Sukhoi State Technical University of Gomel

Address for correspondence

246746, Republic of Belarus,
Gomel, Oktyabrya Ave., 48
Sukhoi State
Technical University of Gomel
Tel.: +375 25 538-03-71
E-mail: levts@gstu.by
Semenchenia Tatyana