

МЕТОДЫ МАТЕМАТИЧЕСКОЙ ОБРАБОТКИ СПЕКТРАЛЬНЫХ ХАРАКТЕРИСТИК МОЛОКА И МОЛОЧНОЙ ПРОДУКЦИИ

ОБЗОРНАЯ СТАТЬЯ

Ирина Александровна Барковская, канд. техн. наук, заведующий лабораторией технологий молочных продуктов
Всероссийский научно-исследовательский институт молочной промышленности, г. Москва
E-mail: i_barkovskaya@vnimi.org

Современные задачи контроля качества молока и молочной продукции требуют внедрения быстрых и достоверных методов анализа. Рамановская спектроскопия является перспективным инструментом экспресс-анализа благодаря высокой чувствительности к молекулярным модификациям и возможности получения воспроизводимых спектральных характеристик. Несмотря на широкий потенциал использования анализа спектров в испытательных и исследовательских целях, высокая информативность данных сопровождается сложностью их интерпретации, обусловленной многомерностью спектральных полос, наличием шумов и перекрывающихся диапазонов. Перечисленные ограничения спектроскопического анализа особенно характерны для многокомпонентных органических систем, таких как молоко и молочные продукты. Специалисты данной области на практике используют широкий перечень математических средств обработки первичных спектров исследуемых объектов и математических подходов для их классификации и прогнозирования количественных физико-химических показателей, технологических параметров и прочее. Однако на сегодняшний день не существует унифицированных рекомендаций по выбору методов обработки и оценки результатов спектроскопических исследований, в том числе и для молочных продуктов. В работе проведено обобщение современных подходов к математической обработке спектральных характеристик, включая методы предварительной обработки, хемометрические алгоритмы и методы машинного обучения. Показано, что эффективная стратегия анализа спектров комбинационного рассеяния включает комплексную предобработку данных (удаление артефактов, коррекция базовой линии, сглаживание, нормализация и коррекция рассеяния), обеспечивающую повышение информативности спектров и их сопоставимость. Установлено, что для моделирования и прогнозирования наиболее эффективными являются методы контролируемого обучения, прежде всего метод частичных наименьших квадратов, а также алгоритмы машинного обучения, позволяющие учитывать сложные нелинейные зависимости. Показано, что интеграция методов предварительной обработки и многовариантного анализа позволяет существенно повысить точность, воспроизводимость и достоверность экспресс-анализа молока и молочных продуктов.

Ключевые слова: молочные продукты, контроль качества, рамановская спектроскопия, математическая обработка, хемометрия, машинное обучение

Для цитирования: Барковская, И. А. Методы математической обработки спектральных характеристик молока и молочной продукции / И. А. Барковская // Молочная промышленность. 2026. № 5. С. 90–96. <https://doi.org/10.21603/1019-8946-2026-5-99>

ВВЕДЕНИЕ

Современная пищевая отрасль сталкивается с вопросами точного контроля качества продуктов и сырья, а также выявления случаев фальсификации продовольственных товаров [1–4]. В данном аспекте применение быстрых и надежных методов анализа необходимо с точки зрения обеспечения безопасности потребителей [5, 6]. На этом фоне рамановская спектроскопия (спектроскопия комбинационного рассеяния) выступает перспективным инструментом реализации оперативного тестирования [7, 8]. Привлекательность метода заключается в перечне преимуществ: использование прибора не разрушает опытный образец, результаты измерений характеризуются точностью и высокой чувствительностью к трансформациям молекулярной структуры [9, 10]. Благодаря этому области применения рамановских спектрометров достаточно обширны – от биомолекул [11, 12] и полимеров [13] до пищевых продуктов [7, 8] и микроорганизмов [14]. Например, в исследова-

ниях [11, 12] ученые приводят возможности метода в части определения каротиноидов и детектирования структурных изменений жировых продуктов при хранении и фальсификации. Авторы в своем обзоре [15] показали перспективность рамановской спектроскопии в сочетании с передовыми стратегиями разделения и концентрирования микроорганизмов для обнаружения, идентификации и дифференциации бактерий, а также для определения их чувствительности к антибиотикам. В молочной отрасли применение метода также широко исследуется в части определения основных компонентов продукта и контаминантов [16, 17]. Описанные исследования подчеркивают потенциал применения метода рамановской спектроскопии в пищевой индустрии как для решения задач идентификации, так и для аутентификации.

Спектры комбинационного рассеяния представляют собой набор большого количества данных в широком диапазоне значений волновых чисел, несущих

информацию о характеристиках множества компонентов пищевой системы [16, 18]. Визуализация и интерпретация результатов исследований затруднена большим количеством пиков в определенных областях спектра, шумов и, возможно, перекрывающихся зон, что особенно актуально для полидисперсных систем, таких как молочная матрица [19]. Для решения этой проблемы и извлечения значимой информации применяют математические подходы к обработке данных – хемометрию [20]. Классические вариации хемометрических методов анализа больших массивов значений показали положительные результаты в спектральных методах измерений [21, 22]. Например, метод главных компонент (PCA) позволяет выявлять скрытые структуры в данных и уменьшать их размерность без значимой потери информативности. Метод частичных наименьших квадратов (PLS) обнаруживает зависимости между спектральными особенностями исследуемых объектов и концентрациями составных компонентов [22]. Иерархический кластерный анализ (HCA) позволяет группировать образцы по сходству их спектров [23]. Применяя на практике перечисленные подходы математической конверсии данных, ученые в своих исследованиях [22] показали возможность построения калибровочных моделей и классификации пищевых продуктов по их спектральным характеристикам. Например, в работе [21] предложен подход на основе оценки спектров комбинационного рассеяния для анализа растительных масел и выявления случаев фальсификации с применением методов PCA и PLS с дискриминантным анализом (PLS-DA). Для классификации семи видов молока (цельное, отборное, с повышенным содержанием кальция, безлактозное, обезжиренное и низкожирное, с повышенным содержанием белка) в работе [20] применяли стратегию последовательной ортогональной PLS-DA, позволившей получить точность анализа до 95 %. Таким образом, математическая обработка данных играет ключевую роль в достижении надежных результатов, в том числе и в количественном выражении, исследований пищевой продукции с применением метода рамановской спектроскопии.

В последние годы для увеличения эффективности обработки спектральных характеристик опытных образцов, помимо хемометрических подходов, активно внедряют современные алгоритмы машинного обучения [24]. Возможности данных подходов позволяют выявить очень тонкие различия в спектрах и строить высокоточные предиктивные модели [9]. В частности, проведенные ранее исследования [24] отражают перспективность применения совокупно-

сти метода рамановской спектроскопии и алгоритмов классификации (метод опорных векторов (SVM), классификатор на основе ансамбля случайных деревьев решений (Random Forest) и другие нейронные сети) для целей аутентификации пищевых продуктов. A. Nedeljkovic и соавторы в своей работе [24] продемонстрировали аспекты использования мощностей представленных алгоритмов в детектировании примесей в мясном сырье с точностью, превышающей показатель 85 %. В некоторых исследованиях авторы заявляют [9] о точности обнаружения патогенов в пищевых продуктах, достигающей 95 % и более. Российские авторы также подчеркивают перспективность применения алгоритмов машинного обучения и хемометрических моделей при анализе рамановских спектров, обращая внимание читателей на проблему физической интерпретации результатов подобных методов [25–27]. Однако, несмотря на значительное количество разработанных подходов, выбор оптимальной стратегии обработки спектральных данных остается сложной задачей. Проблематика подбора необходимого математического алгоритма оценки результатов исследований обусловлена рядом факторов, таких как природа исследуемого объекта, качество исходных спектров и поставленных аналитических целей. Отсутствие унификации подхода к выбору методов обработки и последующего моделирования и / или прогнозирования может приводить к потере значимой информации и снижению точности интерпретации результатов. В связи с этим **целью работы** являлось обобщение различных подходов к обработке спектральных характеристик и подбор наиболее эффективных математических методов анализа рамановских спектров молока и молочных продуктов.

ОБЪЕКТЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Объектом исследования являлись научные публикации, освещающие применение рамановской спектроскопии для анализа пищевых систем, в том числе молока и молочных продуктов, а также подходы к математической обработке спектральных данных. Поиск научной литературы осуществлялся с использованием электронных баз данных ScienceDirect, PubMed, GoogleScholar и eLIBRARY.RU. В выборку включали научные труды, преимущественно опубликованные в период с 2021 по 2026 г., что позволило охватить наиболее актуальные направления развития областей применения рамановской спектроскопии в анализе пищевых

систем. Подбор источников проводили по перечню ключевых выражений: предварительная обработка рамановских спектров, raman spectral preprocessing, хемометрия в рамановской спектроскопии, chemometrics raman spectroscopy, определение качества молока с применением рамановской спектроскопии, raman spectroscopy milk quality. В работе использовали приемы систематизации и сравнительного анализа современных методов предварительной обработки спектров и многовариантного анализа.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Спектры комбинационного рассеяния несут в себе большой массив информации о колебаниях химических связей исследуемых объектов, требующий анализа данных [7]. В связи с этим на практике применяют предварительную обработку с целью извлечения спектральных характерных полос, затем создают модели

классификации или прогнозирования с последующим определением аналитов в испытуемых объектах [7, 21]. Предварительная обработка спектров используется для удаления спектральных шумов, артефактов и неинформативных сигналов из необработанных данных, обусловленных особенностями проведения процедуры получения спектров [7]. Методы обработки данных включают коррекцию пиков и фона, калибровку волновых чисел и интенсивности, сглаживание, нормализацию и уменьшение размерности (табл. 1) [7, 21]. При выборе методов обработки данных важно протестировать и оценить различные методические подходы, иначе значимая информация может быть утеряна [7].

Представленные в таблице 1 методы предварительной обработки спектров комбинационного рассеяния отражают многоэтапную стратегию повышения информативности данных и подготовки их к последующему

Таблица 1. Различные подходы к предобработке спектральных данных

Подход	Основное назначение	Принцип работы	Преимущества	Ограничения	Источник
Устранение артефактов (Cosmic ray removal)	Устранение оди- ночных выбро- сов сигнала	Детектирование аномально высоких интенсивностей и их замена интерполяцией или медианным значением	Сохранение целост- ности спектра, улучшение вос- производимости	Возможна потеря узких полос при некорректной настройке	[21]
Коррекция базовой линии (Baseline correction)	Удаление фонового сигнала (флюо- ресценция и пр.)	Аппроксимация фона и его вычитание	Улучшение количе- ственной интерпре- тации спектров	Переэкореция может исказить интенсивность	[21]
Сглаживание (Smoothing)	Повышение отно- шения сигнал/шум	Фильтрация высокочастотных колебаний (Savitzky-Go- lay, moving average)	Повышение ста- бильности моделей	Чрезмерное сглаживание снижает разрешение	[21]
Нормализация интенсивности (Normalization)	Приведение спек- тров к сопостави- мому масштабу	Деление спектра на нормирующий коэффициент (vector norm, area normalization)	Устранение вариабельности условий измерения	Может скрывать абсолютные различия	[9]
Коррекция рассеяния (multiplicative scatter correction или standard normal variate)	Устранение мультипликати- вых эффектов	Линейная трансфор- мация спектров отно- сительно среднего	Повышение сопоставимо- сти образцов	Требуется корректного выбора референса	[21]
Вычисление производных спектра	Усиление пере- крывающих полос	Расчет первой или второй производной	Повышение разрешающей способности	Усиление шума	[28]
Фильтрация шума (Denoising)	Удаление случай- ных колебаний	Вейвлетная фильтрация, медианные фильтры	Сохранение формы полос при правиль- ной настройке	Высокая вычислительная сложность	[28]
Выбор спектральных диапазонов (Wavelength selection)	Удаление неинфор- мативных областей	Отбор зон с аналити- ческой значимостью	Повышение точ- ности моделей	Возможна потеря скрытой информации	[28]
Уменьшение размерности (Dimensionality reduction)	Упрощение струк- туры данных	Преобразование исход- ных данных в простран- ство меньшей размер- ности с сохранением ключевой информации	Снижение пере- обучения	Снижение прямой интерпретируемости вклада исходных переменных	[9]
Многомерная корреляционная обработка	Извлечение дополнительной информации	Анализ взаимосвязей спектральных переменных	Повышение чувствительно- сти анализа	Требуется больших наборов данных	[28]

хеометрическому анализу [21]. На начальных этапах применяют процедуры удаления артефактов и коррекции базовой линии, позволяющие устранить локальные всплески и фоновые искажения, не относящиеся к характеристикам испытуемого объекта [21]. Далее используют методы сглаживания и фильтрации шума, направленные на повышение отношения сигнал/шум при сохранении аналитически значимых особенностей спектральных полос [28]. Важную роль при интерпретации информации играют нормализация интенсивности и коррекция рассеяния, обеспечивающие сопоставимость спектров, полученных при вариабельности пробоподготовки и оптических условий измерения, что особенно актуально при исследовании многокомпонентных органических матриц, таких как молоко и молочные продукты [9, 21]. Дополнительное усиление информативности достигается за счет вычисления спектральных производных, выбора аналитически значимых диапазонов и методов уменьшения размерности, позволяющих выделить ключевые факторы вариабельности и снизить риск переобучения моделей [28]. Таким образом, предобработка формирует оптимизированное представление спектральных данных, на основе которого в дальнейшем можно применять многомерные методы обработки данных и строить прогностические модели для классификации образцов, выявления закономерностей и количественного определения целевых параметров. Наиболее эффективной стратегией анализа спектров комбинационного рассеяния молока и молочных продуктов является комплексная обработка, включающая удаление артефактов и коррекцию базовой линии, сглаживание, нормализацию и коррекцию рассеяния, обеспечивающие сопоставимость спектров многокомпонентных систем. Дополнительное использование производных и методов уменьшения размерности позволяет повысить информативность данных и точность последующего моделирования [21].

Многомерные модели классификации извлекают информацию из спектров комбинационного рассеяния, применяя хеометрические методы для ранжирования исследуемых объектов [7] (табл. 2). На основе наличия дополнительной предварительной информации эти модели можно разделить на модели распознавания образцов по алгоритму «неконтролируемое обучение» и «контролируемое обучение» [7, 20, 21, 23]. Перечисленные виды алгоритмов отличаются последовательностью обработки информации: первая модель получает неразмеченные данные и самостоятельно выявляет их внутренние закономерности, а вторая модель машинного обучения получает размеченные данные, где каждая точка в тренировоч-

ном наборе связана с конкретной категорией (меткой) [7, 20, 21]. Наиболее часто применяемым подходом в области неконтролируемого распознавания образцов для обнаружения скрытых структур в немаркированных данных является PCA [7, 20–22]. Контролируемое распознавание образцов применяют для построения математических моделей и последующей классификации неизвестных образцов [7]. К часто используемым дискриминантным методам относятся линейный дискриминантный анализ, PLS-DA, SVM и искусственные нейронные сети [7, 20–22]. Модели прогнозирования определяют взаимосвязь и влияние переменных и используют эту информацию для прогнозирования параметра нового наблюдения [7]. Поскольку выбор подходящей математической модели имеет решающее значение, было разработано несколько систем оценки результатов моделирования [7, 9]. Например, коэффициент детерминации (R^2) и среднеквадратичная ошибка (RMSE) часто используют на практике для оптимизации параметров модели и оценки ее производительности [7, 9].

Приведенные в таблице 2 методы хеометрической обработки спектров комбинационного рассеяния демонстрируют широкую вариативность и аналитические возможности, охватывающие как классификационный анализ данных, так и их количественную оценку. Применение того или иного подхода определяется, в первую очередь, задачами исследования, объемом массива информации и сложностью объекта испытаний. Методы обработки данных по алгоритму неконтролируемого обучения используют для выявления скрытых закономерностей в многомерных спектральных данных, снижения их размерности и визуализации группировок образцов, что облегчает выбор информативных спектральных признаков и стратегий дальнейшего моделирования [20–22]. Подходы интерпретации спектральных характеристик в алгоритме контролируемого обучения направлены на решение прикладных задач идентификации и прогнозирования целевых показателей. Подобные модели используют для определения взаимосвязей между спектральными переменными и целевыми показателями, обеспечивая количественный анализ состава и классификацию образцов [9, 20–22, 24]. Дополнительные возможности предоставляет применение алгоритмов машинного обучения, таких как метод опорных векторов, случайный лес и искусственные нейронные сети [9, 29]. Перечисленные инструменты эффективно выявляют нелинейные зависимости и обеспечивают высокую точность анализа многокомпонентных органических матриц.

Таблица 2. Виды многовариантных моделей классификации исследуемых объектов по спектрам комбинационного рассеяния

Метод	Тип метода	Основное назначение	Принцип работы	Преимущества	Применение	Источник
Метод главных компонент	Неконтролируемое обучение	Эксплораторный анализ данных, выявление структуры, аномалий и группировок	Преобразует исходные спектры комбинационного рассеяния в систему ортогональных главных компонент, каждая из которых объясняет максимальную долю вариации	Снижение размерности, визуализация скрытых трендов, повышение устойчивости последующей классификации	Выявление факта фальсификации, отбор информативных спектральных полос, предварительный анализ спектров комбинационного рассеяния	[20–22]
Метод частичных наименьших квадратов	Контролируемое обучение	Построение прогностических моделей (классификация и количественный анализ)	Обнаруживает скрытые переменные, максимально объясняющие ковариацию между спектрами и целевыми параметрами	Учет множества спектральных переменных, эффективен для сложных матриц	Количественное изменение компонентов, количественное выявление фальсификации	[20–22]
Дискриминантный анализ / регрессия методом частичных наименьших квадратов	Контролируемое обучение	Классификация и регрессия	Проецирует данные в пространство факторов, обеспечивающих максимальное разделение классов или точное прогнозирование	Совмещение качественного и количественного анализа	Выявление фальсификации, оценка доли фальсифицирующего компонента	[21]
Иерархический кластерный анализ	Неконтролируемое обучение	Классификация образцов по сходству	Рассчитывает расстояние между спектрами и формирует древовидную структуру (дендрограмму)	Наглядность результатов, отсутствие необходимости обучения данных	Классификация видов сырья, обнаружение патогенов, выявление однородных партий	[23]
Метод опорных векторов	Контролируемое обучение	Высокоточная классификация	Строит гиперплоскость максимального разделения классов, использует ядровые функции для нелинейных зависимостей	Высокая точность, устойчивость к переобучению, эффективен при малых выборках	Обнаружение фальсификации, выявление примесей	[9]
Классификатор на основе ансамбля случайных деревьев решений (Random Forest)	Контролируемое обучение	Классификация и регрессия	Ансамбль решающих деревьев, обученных на разных подвыборках	Устойчивость к шуму, интерпретируемость	Автоматическая идентификация образцов, фиксация отклонений от стандартных значений	[24]
Искусственные нейронные сети	Контролируемое обучение	Сложная классификация и количественное прогнозирование	Обучаются распознавать нелинейные паттерны спектров, сверточные нейронные сети автоматически извлекают признаки для классификации или прогнозирования	Высокая точность, возможность анализа сложных корреляций	Классификация микроорганизмов по спектральным полосам, количественная оценка фальсификации	[9, 29]

Выбор многомерных методов обработки данных в первую очередь определяется задачами исследования. Для целей классификации молока и молочных продуктов (например, по массовой доле жира, белка и пр.) целесообразно применение методов PCA/HCA и алгоритмов PLS-DA/SVM. При определении качественной и количественной фальсификации молочных продуктов наиболее эффективно использование PLS/PLSR, а также моделей машинного обучения. Резюмируя вышеизложенное, можно заключить, что стратегия обработки спектров комбинационного рассеяния молочных систем предполагает комплексное использование математических подходов на базе моделей контролируемого и неконтролируемого обучения, что в конечном результате позволяет повысить достоверность экспресс-анализа, решения задач по аутентификации, идентификации и контролю качества молочной продукции.

тролируемого обучения, что в конечном результате позволяет повысить достоверность экспресс-анализа, решения задач по аутентификации, идентификации и контролю качества молочной продукции.

ВЫВОДЫ

Проведенная аналитическая работа подчеркивает перспективы применения метода рамановской спектроскопии как инструмента для экспресс-анализа в молочной промышленности. Данный подход обладает рядом преимуществ, таких как неразрушающая природа испытаний, высокая чувствительность и широкий перечень возможностей применения. Вме-

сте с тем высокая информативность спектров комбинационного рассеяния сопровождается сложностью их интерпретации, обусловленной многомерностью данных, наличием шумов и перекрывающихся спектральных полос, что требует применения методов математической обработки массивов данных. Представленный обзор подходов к оценке результатов измерений показал, что эффективная интерпретация спектральных характеристик возможна только при условии комплексного использования предварительной обработки и многомерного анализа. Предобработка позволяет устранить артефакты и повысить информативность спектров, а алгоритмы анализа данных по моделям контролируемого обучения и неконтролируемого обучения обеспечивают выявление скрытых закономерностей, классификацию

образцов и количественное прогнозирование их состава. Дополнительное применение алгоритмов машинного обучения расширяет аналитические возможности за счет учета нелинейных зависимостей.

Показано, что для целей ранжирования исследуемых образцов наиболее целесообразно применять методы PCA/HCA и алгоритмы PLS-DA/SVM, а для задач определения качественной и количественной фальсификации молочных продуктов – подходы PLS/PLSR и модели машинного обучения. В совокупности перечисленные стратегии позволяют повысить точность и достоверность экспресс-анализа и подтверждают перспективность применения рамановской спектроскопии в задачах контроля качества, идентификации и аутентификации молока и молочных продуктов. ■

Поступила в редакцию: 14.04.2026

Принята в печать: 15.09.2026

SPECTRAL PROFILE OF MILK AND DAIRY PRODUCTS: METHODS OF MATHEMATICAL PROCESSING

Irina A. Barkovskaya

All-Russian Dairy Research Institute, Moscow

REVIEW ARTICLE

Dairy quality control requires rapid and reliable analytical methods. Raman spectroscopy is time-saving, sensitive to molecular modifications, and reproducible. However, the resulting data are difficult to interpret due to complex multidimensional spectra, noise, and overlapping bands. These limitations are typical of multicomponent organic systems, such as milk and dairy products. A wide range of mathematical approaches and processing tools is required to analyze the primary spectra, classify them, model quantitative physicochemical indicators, and select optimal processing parameters. Nevertheless, no unified recommendations exist for the selection of processing and interpretation methods. This paper summarizes modern approaches to the mathematical processing of spectral data, including preprocessing methods, chemometric algorithms, and machine learning techniques. To improve the information content and comparability of the spectra, an effective analysis strategy involves comprehensive preprocessing, including artifact removal, baseline correction, smoothing, normalization, and scattering correction. Supervised learning methods are especially effective for modeling and prediction, notably partial least squares (PLS), as well as machine learning algorithms that account for complex nonlinear relationships. Integrated preprocessing and multivariate analysis improve the accuracy, reproducibility, and reliability of rapid dairy analysis.

Keywords: dairy products, quality control, Raman spectroscopy, mathematical processing, chemometrics, machine learning

СПИСОК ЛИТЕРАТУРЫ

1. Юрова, Е. А. Особенность оценки состава жировой фазы многокомпонентной пищевой продукции, выработанной из молочного сырья / Е. А. Юрова, А. О. Евсюкова, С. А. Фильчакова // Пищевая промышленность. 2025. № 5. С. 86–90. <https://doi.org/10.52653/PPI.2025.5.5.015>; <https://elibrary.ru/schcfcg>
2. Юрова, Е. А. Оценка подлинности молока и молочной продукции согласно ГОСТ Р 72209-2025 / Е. А. Юрова // Молочная промышленность. 2025. № 5. С. 2–4. <https://elibrary.ru/waoxda>
3. Юрова, Е. А. Разработка критериев оценки продуктов с высоким содержанием белка / Е. А. Юрова, С. А. Фильчакова // Пищевая промышленность. 2025. № 10. С. 80–85. <https://doi.org/10.52653/PPI.2025.10.10.015>; <https://elibrary.ru/hshscr>
4. Ryabova, A. E. Effects of storage conditions on milk powder properties / A. E. Ryabova, V. K. Semipyatnyi, A. G. Galstyan // Journal of Dairy Science. 2023. Vol. 106(10). P. 6741–6758. <https://doi.org/10.3168/jds.2022-23094>
5. Галстян, А. Г. Киберфизические компоненты пищевой метаинженерии / А. Г. Галстян [и др.] // Вестник Российской академии наук. 2025. № 6. С. 77–84. <https://doi.org/10.31857/S0869587325060099>; <https://elibrary.ru/fbgugw>
6. Криницына, А. А. Оценка распределения остаточных количеств лекарственного препарата пенициллина-G в молоке и молочных продуктах / А. А. Криницына, А. Н. Петров, А. Г. Кручинин // Вестник КрасГАУ. 2024. № 3(204). С. 198–205. <https://doi.org/10.36718/1819-4036-2024-3-198-205>; <https://elibrary.ru/gjbmssa>
7. Benattia, F. K. Methods and applications of Raman spectroscopy: A powerful technique in modern research, diagnosis, and food quality control / F. K. Benattia, Z. Arrar, F. Dergal // Current Nutrition & Food Science. 2024. Vol. 20(1). P. 41–61. <https://doi.org/10.2174/1573401319666230503150005>
8. Feng, Y. Advancing food safety and quality assessment: A comprehensive review of non-destructive analytical technologies / Y. Feng [et al.] // Analytical Methods. 2025. Vol. 17. P. 4697–4717. <https://doi.org/10.1039/D5AY00647C>
9. Petersen, M. Application of Raman spectroscopic methods in food safety: A review / M. Petersen, Z. Yu, X. Lu // Biosensors. 2021. Vol. 11(6). Art. no. 187. <https://doi.org/10.3390/bios11060187>
10. Барковская, И. А. Сравнение методов ИК- и Раман-спектроскопии для оценки структурных изменений в молоке при тепловой обработке / И. А. Барковская [и др.] // Пищевая метаинженерия. 2025. Т. 3, № 3. С. 21–38. <https://doi.org/10.3390/bios11060187>; <https://elibrary.ru/hsknhe>
11. Kolašinac, S. M. Raman spectroscopy in the characterization of food carotenoids: Challenges and prospects / S. M. Kolašinac [et al.] // Foods. 2025. Vol. 14(6). Art. no. 953. <https://doi.org/10.3390/foods14060953>

ВОССТАНОВИТЕЛИ МОЛОКА, ДИСПЕРГАТОРЫ, ГОМОГЕНИЗАТОРЫ ВЫСОКОГО ДАВЛЕНИЯ

ВОССТАНОВИТЕЛИ МОЛОКА



МНОГОКАМЕРНЫЕ СМЕСИТЕЛИ-ДИСПЕРГАТОРЫ СДГ-20

Производительность - до 40 000 л/час
Напор - до 5 атм



Производительность - до 30 000 л/час
Мощность - 18,5 кВт
Внесение и растворение сухого молока, сахара, солей

ДИСПЕРГАТОРЫ (РДН)



РДН-1, РДН-2, РДН-5, РДН-7, РДН-10

РДН-1 (1м3/час, 2атм, 1,5кВт)
РДН-2 (3м3/час, 2 атм, 4кВт)
РДН-5 (15м3/час, 2атм, 7,5кВт)
РДН-5-01 (15м3/час, 2атм, 11кВт)
РДН-7 (20м3/час, 2атм, 11кВт)
РДН-7-01 (20м3/час, 2атм, 15кВт)
РДН-10 (25м3/час, 2атм, 15кВт)
РДН-10 (25м3/час, 2атм, 18,5кВт)
РДН-10-02 (25м3/час, 2атм, 22кВт)
РДН-10-04 (25м3/час, 2атм, 30кВт)
РДН-10/20 (40м3/час, 4атм, 22кВт)



ГОМОГЕНИЗАТОРЫ ВЫСОКОГО ДАВЛЕНИЯ (ГМ)



5 000 л/час
до 200 атм
37 кВт

ГМЗ,0/20Д

3 000 л/час
до 200 атм
22,0 кВт

ГМ2,5/20М2Д

2 500 л/час
до 200 атм
18,5 кВт

ГМ1,25/20М2Д

1 250 л/час
до 200 атм
11 кВт

ГМ0,5/20М1Д

500 л/час
до 200 атм
4 кВт

12. **Esmonde-White, K.** Raman spectroscopy in analyzing fats and oils in foods / K. Esmonde-White [et al.] // Spectroscopy. 2022. Vol. 37(36). P. 34–45. <https://doi.org/10.56530/spectroscopy.jb8390i4>
13. **Bokobza, L.** Spectroscopic techniques for the characterization of polymer nanocomposites: A review / L. Bokobza // Polymers. 2017. Vol. 10(1). Art. no. 7. <https://doi.org/10.3390/polym10010007>
14. **Allakhverdiev, E. S.** Spectral insights: Navigating the frontiers of biomedical and microbiological exploration with Raman spectroscopy / E. S. Allakhverdiev [et al.] // Journal of Photochemistry and Photobiology B: Biology. 2024. Vol. 252. Art. no. 112870. <https://doi.org/10.1016/j.jphotobiol.2024.112870>
15. **Rodriguez, L.** Recent advances of Raman spectroscopy for the analysis of bacteria / L. Rodriguez, Z. Zhang, D. Wang // Analytical Science Advances. 2023. Vol. 4(3–4). P. 81–95. <https://doi.org/10.1002/ansa.202200066>
16. **McCarthy, U.** Potential of Raman spectroscopy for in-line measurement of raw milk composition / U. McCarthy [et al.] // Food Control. 2023. Vol. 152. Art. no. 109862. <https://doi.org/10.1080/10408398.2018.1528436>
17. **He, H.** Applications of Raman spectroscopic techniques for quality and safety evaluation of milk: A review of recent developments / H. He [et al.] // Critical Reviews in Food Science and Nutrition. 2019. Vol. 59(5). P. 770–793. <https://doi.org/10.1080/10408398.2018.1528436>
18. **Муклецова, Е. И.** Основные спектральные характеристики молока и молочных продуктов / Е. И. Муклецова, И. А. Барковская // Пищевая промышленность. 2026. № 1. С. 106–111. <https://doi.org/10.52653/PPI.2026.1.1.022>; <https://elibrary.ru/kwyohi>
19. **Surkova, A.** Analysis of milk microstructure using Raman hyperspectral imaging / A. Surkova, A. Bogomolov // Molecules. 2023. Vol. 28(6). Art. no. 2770. <https://doi.org/10.3390/molecules28062770>
20. **Mohammadi, S.** Vibrational spectroscopy data fusion for enhanced classification of different milk types / S. Mohammadi, A. Gowen, C. O'Donnell // Heliyon. 2024. Vol. 10(16). Art. no. e36385. <https://doi.org/10.1016/j.heliyon.2024.e36385>
21. **Chang, B.** Rapid quantitative determination of adulteration of camellia oil using portable Raman spectroscopy and chemometrics / B. Chang [et al.] // Processes. 2025. Vol. 13(2). Art. no. 456. <https://doi.org/10.3390/pr13020456>
22. **Li, Y. S.** Raman spectroscopy in the analysis of food and pharmaceutical nanomaterials / Y. S. Li, J. S. Church // Journal of Food and Drug Analysis. 2014. Vol. 22(1). P. 29–48. <https://doi.org/10.1016/j.jfda.2014.01.003>
23. **Taylan, O.** Detection of lard in butter using Raman spectroscopy combined with chemometrics / O. Taylan [et al.] // Food Chemistry. 2020. Vol. 332. Art. no. 127344. <https://doi.org/10.1016/j.foodchem.2020.127344>
24. **Nedeljkovic, A.** The feasibility of artificial intelligence and Raman spectroscopy for determining the authenticity of minced meat / A. Nedeljkovic [et al.] // Foods. 2025. Vol. 14(17). Art. no. 3084. <https://doi.org/10.3390/foods14173084>
25. **Павлов, В. Н.** Использование интеллектуальных методов обработки данных раман-спектроскопии для диагностики злокачественных опухолей / В. Н. Павлов [и др.] // Медицинский вестник Башкортостана. 2018. Т. 13, № 3(75). С. 43–47. <https://elibrary.ru/sqrsq1>
26. **Савельева, Т. А.** Методы машинного обучения для анализа спектрально-разрешенных изображений в нейроонкологии / Т. А. Савельева [и др.] // Biomedical Photonics. 2024. Т. 13, № 4. С. 40–54. <https://doi.org/10.24931/2413-9432-2024-13-4-40-54>; <https://elibrary.ru/inzwhk>
27. **Тимурзиева, А. Б.** Использование раман-флуоресцентных технологий в ранней диагностике воспалительных и опухолевых заболеваний как часть стратегического направления формирования общественного здоровья и инструмент для повышения качества оказания медицинской помощи: обзор литературы / А. Б. Тимурзиева // Лазерная медицина. 2021. Т. 25, № 4. С. 42–50. <https://doi.org/10.37895/2071-8004-2021-25-4-42-50>; <https://elibrary.ru/opnkhk>
28. **Yan, C.** A review on spectral data preprocessing techniques for machine learning and quantitative analysis / C. Yan // iScience. 2025. Vol. 28(7). Art. no. 112759. <https://doi.org/10.1016/j.isci.2025.112759>
29. **Wu, X.** Identification and quantification of adulterated honey by Raman spectroscopy combined with convolutional neural network and chemometrics / X. Wu [et al.] // Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy. 2022. Vol. 274. Art. no. 121133. <https://doi.org/10.1016/j.saa.2022.121133>



ООО ИТЦ "ПИЩМАШСЕРВИС"
+7 (495)775-18-00
www.pmserv.com
Москва, Мажоров пер., д.14, стр.5

СДЕЛАНО
В
РОССИИ

На правах рекламы