







https://doi.org/10.51885/3134-8025_IICS_2026_1_4

МРНТИ 28.23.01

ИЗВЛЕЧЕНИЕ ТЕКСТУРНЫХ ХАРАКТЕРИСТИК МРТ-ИЗОБРАЖЕНИЙ КОЛЕННОГО СУСТАВА С ПРИМЕНЕНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ РАЗРЫВОВ МЕНИСКА

МЕНИСКТИҢ ЖЫРТЫЛУЫН ЖІКТЕУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ
АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ТІЗЕ БУЫНЫНЫҢ
МРТ СУРЕТТЕРІНІҢ ТЕКСТУРАЛЫҚ СИПАТТАМАЛАРЫН АЛУ

EXTRACTION OF TEXTURE FEATURES FROM KNEE JOINT MRI IMAGES USING MACHINE LEARNING ALGORITHMS FOR CLASSIFICATION OF MENISCAL TEARS

М.А. Карменова ¹, З.М. Төлеуғазы ², Т.Б. Дуанбаева ², А.С. Тлебалдинова ^{3*},
С.К. Кумаргажанова ³, Z. Omiotek ⁴

¹Восточно-Казахстанский университет им. С. Аманжолова, г. Усть-Каменогорск, Казахстан

²Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

³Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

⁴Люблинский технический университет, г. Люблин, Польша

*Автор-корреспондент: Тлебалдинова Айжан Солтанғалиевна, e-mail: atlebaldinova@edu.ektu.kz

Ключевые слова:

МРТ-изображения,
мениск, текстурный
анализ, классификация,
признаки, RFE, ANOVA,
критерий Fisher

АННОТАЦИЯ

В работе представлен подход к автоматической классификации состояния мениска коленного сустава на основе текстурного анализа МРТ-изображений с применением методов машинного обучения. Для извлечения признаков использовалось программное обеспечение MaZda 4.6, включающее показатели гистограмм, матрицы совместного появления уровней серого (GLCM), матрицы длин серий (GLRLM) и вейвлет-признаки. Отбор наиболее информативных признаков выполнялся методами RFE, ANOVA и Fisher, что позволило сократить исходный набор с 297 до 16 признаков. Для бинарной классификации классов normal и tear применялись алгоритмы MLP и SVM, показавшие высокую точность (до 95 %) при использовании оптимальных подмножеств признаков. Полученные результаты подтверждают диагностическую значимость текстурных характеристик и демонстрируют эффективность их использования для автоматизированного выявления разрывов мениска, что может быть полезно для поддержки клинической диагностики и прогностической оценки состояния коленного сустава.



Түйінді сөздер:

МРТ кескіндері, мениск,
текстуралық талдау,
жіктеу, белгілер, RFE,
ANOVA, Fisher критерийі

ТҮЙІНДЕМЕ

Бұл мақалада машиналық оқыту әдістерін қолдана отырып, МРТ кескіндерінің текстуралық талдауы негізінде тізе буыны менискісінің жағдайын автоматты түрде жіктеу тәсілі ұсынылған. Белгілерді шығару үшін гистограмма көрсеткіштерін, сұр деңгейлердің бірлескен пайда болу матрицасын (GLCM), серия ұзындықтарының матрицасын (GLRLM) және вейвлет-белгілерді қамтитын MaZda 4.6 бағдарламалық қамтамасыз етуі пайдаланылды. Ең ақпараттық белгілерді іріктеу RFE, ANOVA және Фишер әдістерімен жүргізіліп, бастапқы 297 белгіден 16 белгіге дейін қысқартуға мүмкіндік берді. Normal және tear кластары үшін бинарлық жіктеуде MLP және SVM алгоритмдері қолданылып, оңтайлы белгілер жиынтығында жоғары дәлдік (95 %-ға дейін) көрсетті. Алынған нәтижелер текстуралық сипаттамалардың диагностикалық маңыздылығын растап, мениск жыртылуын автоматтандырылған түрде анықтаудың тиімділігін көрсетеді, бұл клиникалық диагностиканы қолдауға және тізе буыны жағдайын болжауға пайдалы болуы мүмкін.

Keywords:

MRI images, meniscus,
texture analysis,
classification, features,
recursive feature
elimination (RFE), analysis
of variance (ANOVA),
Fisher's criterion.

ABSTRACT

This paper presents an approach to automatic classification of knee meniscus condition based on texture analysis of MRI images using machine learning methods. Feature extraction was performed with MaZda 4.6 software, including histogram features, gray-level co-occurrence matrix (GLCM), gray-level run-length matrix (GLRLM), and wavelet features. The most informative features were selected using RFE, ANOVA, and Fisher methods, reducing the original set from 297 to 16 features. For binary classification of the normal and tear classes, MLP and SVM algorithms were applied, achieving high accuracy (up to 95 %) when optimal feature subsets were used. The results confirm the diagnostic significance of texture characteristics and demonstrate their effectiveness for automated detection of meniscal tears, which may be useful for supporting clinical diagnosis and prognostic assessment of knee joint condition.

ВВЕДЕНИЕ

За последние десять лет подходы, использующие применение методов машинного обучения на основе искусственного интеллекта для обнаружения различного рода заболеваний у пациентов, приобрели значительную популярность в медицине. На сегодня в различных областях медицины применяются определенные методы диагностики, позволяющие получить подробные исследования для установления точного диагноза заболеваний у пациентов. Среди таких методов наиболее высокую популярность получила магнитно-резонансная томография (далее МРТ).

МРТ является инструментальным методом диагностики, который дает возможность получить самые подробные послойные снимки практически любой части человеческого тела. Важно отметить, что МРТ по сравнению с другими методами позволяет визуализировать мягкие ткани. Данный метод зарекомендовал себя вполне безопасным и не требует проведения каких-либо болезненных процедур и манипуляций по отношению к пациентам. Также все больше исследований рассматривают этот метод для раннего выявления многих заболеваний. Надо отметить, что большинство исследований подобного рода с использованием сканирования МРТ проводились на коленном суставе. В целом анатомия и структура коленного сустава являются самыми крупными и сложными в организме человека. Среди часто встречающихся и наиболее распространенных видов

травм коленного сустава выступают менисковые повреждения, а также повреждения передней крестообразной связки (ПКС) и др. Разрывы мениска чаще всего приводят к дегенерации хряща и костей, которая вызывает боль и потерю подвижности. В связи с этим МРТ-визуализация позволяет 2D и 3D визуализировать колено и обнаруживать разрывы мениска.

Исходя из различных видов травм коленного сустава, большинство исследований стремятся разработать полностью автоматизированные методы и подходы для диагностической и прогностической оценки состояния травмы. В таких подходах авторы применяют модели глубокого обучения, а также классические методы для решения задачи сегментации и классификации видов травм. Важной составляющей или одним из главных исследовательских этапов при разработке подобных подходов выступает текстурный анализ.

Текстурный анализ МРТ-изображений способен предоставить важную информацию, а именно позволяет извлечь текстурные признаки для разделения классов по исследуемым наборам данных, в нашем случае по типам разрывов мениска. Тем самым поиск новых текстурных признаков дает возможность расшифровать результат МРТ-изображений и применять их в итоговых диагностических и предиктивных моделях оценки данных.

В подобных исследованиях для получения диагностической информации необходимо изучить текстуру изображений. В целом при анализе МРТ-изображений недостаточно анализировать свойства изображения на основе только точечной яркости, следует учитывать статистику изображения более высокого порядка (Materka A., 2004). Количественное определение текстуры, а именно ее описание по точно определенным параметрам, представляет возможность для извлечения информации о свойствах ткани (Materka A., 2004). Численные значения параметров текстуры могут быть использованы для классификации различных областей на изображении, представляющих, например, либо ткани разного происхождения, либо нормальные и аномальные ткани данного вида (Materka A., 2004). Изменения правильно выбранных параметров текстуры с течением времени могут количественно отражать изменения в физической структуре ткани (Materka A., 2004).

Целью настоящей работы является разработка и оценка подхода к бинарной классификации состояния мениска коленного сустава (normal/tear) на основе текстурного анализа МРТ-изображений с использованием методов машинного обучения. В рамках исследования ставится задача выявления информативных текстурных признаков, оптимизации их подмножеств с помощью методов отбора признаков (ANOVA, Fisher, RFE) и оценки эффективности различных алгоритмов классификации (Linear Discriminant Analysis (LDA), Support Vector Machine (SVM), k-Nearest Neighbors (KNN), Decision Tree (DT), Multilayer Perceptron (MLP) и Random Forest (RF).) для повышения точности и надежности диагностики разрывов мениска.

ОБЗОР ЛИТЕРАТУРЫ

На сегодняшний день большинство применяемых методов анализа текстур основаны на анализе матрицы совместного появления серого уровня (GLCM - Gray Level Co-occurrence Matrix). В (Aoki, et al., 2018), авторы проводят исследование для проверки эффективности анализа текстуры в сравнении между анализом текстуры на основе T2map МРТ и гистологическим анализом дегенерации мениска у пациентов с остеоартритом (ОА) коленного сустава. В эксперименте были использованы 60 образцов мениска, среди которых 26 медиальных менисков и 34 боковых мениска, полученных у 11 пациентов с прогрессирующей или терминальной стадией коленного ОА. Коленные суставы пациентов были проанализированы с помощью МРТ 3.0Т. Текстурный анализ мениска был

выполнен на корональной плоскости T2map с применением метода GLCM. Текстуальный анализ и статистический анализ проводились с использованием ПО MATLAB 2017a, где значение $p < 0,05$ считалось статистически значимым. В результате проведения текстурного анализа были извлечены 4 текстурные особенности: контрастность 0° , контрастность 90° , дисперсия и энтропия, а также T2 были извлечены для каждой интересующей области на каждом срезе. Гистологическая оценка мениска проведена на разделенных 4 областях мениска. По утверждениям авторов исследования, показатели текстурного анализа, включая контраст 0° , контраст 90° , дисперсию и энтропию менисков, не были связаны со значением T2 менисков пациентов. Также показатели текстурного анализа энтропия и контрастность 90° не были связаны с гистологическими показателями менисков пациентов. Таким образом, авторы доказывают, что текстурный анализ дегенерации менисков, связанный с ОА коленного сустава, коррелировал с гистологическим анализом дегенерации менисков у пациентов с ОА коленного сустава, в то время как значения T2 дегенерации менисков не было. В (Juras, et al., 2021) авторы проводят исследование с целью изучения особенностей текстуры на картах T2 в качестве маркера для различения зрелости восстанавливаемой хрящевой ткани в коленном суставе после процедур микроперелома (MFX) и матрикс-ассоциированной трансплантации хондроцитов (МАСТ). Исследование авторов также опирается на метод GLCM, на основе которого был извлечен двадцать один текстурный признак. Различия между методами восстановления хрящевой ткани коленного сустава оценивали линейной регрессией для разных областей бедренной кости. Стабильность и воспроизводимость текстурных признаков определяли через внутриклассовую изменчивость и анализ ROC-кривых. В результате проведенного исследования авторы выявили значимые различия текстурных характеристик, такие как автокорреляция, однородность и энтропия, в разных зонах хряща. Ткань после МАСТ оказалась ближе к структуре здорового хряща через 24 месяца, чем после MFX. Таким образом, текстурный анализ GLCM дополняет картирование T2, повышая чувствительность метода к структурным изменениям хрящевой ткани. Как и в (Juras, et al., 2021), также в (Janacova, et al., 2022), реализованы исследования на основе GLCM для анализа текстуры, который предоставляет дополнительную информацию о состоянии и созревании восстановленной ткани, а также о прилежащем хряще. Текстурные характеристики, такие как автокорреляция и дисперсия уровня серого, показали различия между восстановленным, прилежащим и контрольным хрящом. В (Janacova, et al., 2021)) исследовательская работа заключалась в сравнении характеристик GLCM для поражений коленного хряща. В исследовании было оценено влияние смещения (направления) расчета GLCM и количество параметров, применяемых для картирования T2, влияющих на характеристики GLCM с учетом микроанатомической структуры хряща. Тем самым в результате анализа текстуры с помощью GLCM были отобраны важные индикаторы, отличающие повреждения хряща. Среди таких индикаторов авторы выявили автокорреляцию, контрастность и однородность. В оценке нормальности данных применялся тест Шапиро-Уилка. Различия в средних значениях T2 и характеристиках GLCM между пораженным и здоровым хрящом исследовались с помощью теста рангов Уилкоксона. Этот же тест использовался для анализа различий в характеристиках GLCM при разных смещениях и параметрах картирования T2. Результаты представлены как среднее значение \pm стандартное отклонение и/или p-значения.

Статистический анализ и визуализация данных проводились с использованием Rstudio версии 1.3.1093. Исходя из результатов исследования, а также по утверждениям авторов, было доказано, что смещение 0° является ключевым параметром для различения пораженного и здорового хряща в коленном суставе, при этом контрастность и однородность значительно различаются только в этом направлении, где текстура

здорового хряща гладкая (однородная) в горизонтальном направлении, когда ROI вращается и уплощается.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Текстурный анализ изображений по сравнению с другими методами анализа изображений имеет значимые преимущества в распознавании структурных особенностей изображений. Текстурный анализ изображений улучшает процесс обнаружения незначительных изменений в структуре ткани или суставов, способствуя повышению эффективности и точности алгоритмов машинного обучения в задачах классификации или сегментации разрывов мениска, а также в подходах, связанных с моделями глубокого обучения. Можно выделить главные особенности и преимущества текстурного анализа изображений в сравнении с другими методами, а именно: эффективный анализ закономерностей в распределении интенсивности пикселей, позволяющий обнаруживать мелкие детали в виде зернистости, повторяющихся узоров или неоднородности; фокус на структурных характеристиках изображений, таких как распределение контраста, а также частотных составляющих, что делает его менее чувствительным к изменениям цвета, освещенности и яркости; применимость к сложным структурам и формам объектов, в случаях, где объекты плохо различимы по форме или цвету, а также не имеют четко выраженных геометрических границ. В таких случаях текстурный анализ позволяет выделить ключевые признаки для классификации или сегментации объектов; устойчивость к шуму, во многих случаях методы текстурного анализа оказываются устойчивыми к шуму в изображении, так как работают с обобщенными характеристиками изображения; хорошая и легкая интеграция с алгоритмами и моделями машинного обучения.

Методология исследования представлена на рисунке 1 и состоит из основных четырех этапов: 1) получение и сбор данных; 2) автоматизация процессов обработки МРТ-изображений; 3) предварительная обработка данных; 4) извлечение текстурных признаков; 5) классификация. В исследовании был сформирован набор данных, состоящий из 2000 МРТ-изображений мениска, из которых 1000 изображений относятся к здоровому мениску (normal), а 1000 к горизонтальным разрывам (tear). Использовались T1-режим МРТ и сагиттальные срезы коленного сустава. Каждое изображение предварительно сегментировалось с выделением области интереса (ROI) для последующего извлечения текстурных признаков. Такой сбалансированный и стандартизированный набор данных обеспечивает корректное обучение и оценку бинарных классификаторов.




Рисунок 1. Общая схема методологии исследования по извлечению текстурных признаков МРТ-изображений мениска коленного сустава и классификации

Примечание – составлено авторами

Процесс предобработки данных начинается с входного файла в формате .csv, содержащего исходные текстурные признаки, извлеченные из МРТ-изображений мениска. На первом шаге проводится предобработка данных, включающая проверку на пропуски, нормализацию или стандартизацию признаков, а также возможное устранение выбросов и шумов. После этого формируются отдельные наборы данных для обучения (train) и тестирования (test), каждый из которых сохраняется в отдельных .csv-файлах; включающие проверку данных, нормализацию признаков и их приведение к средним значениям (means), что обеспечивает согласованность масштабов и устраняет влияние разных диапазонов признаков. Эти подготовленные файлы служат входными данными для последующих этапов построения и обучения моделей машинного обучения, обеспечивая корректность и сопоставимость данных между этапами обучения и валидации.

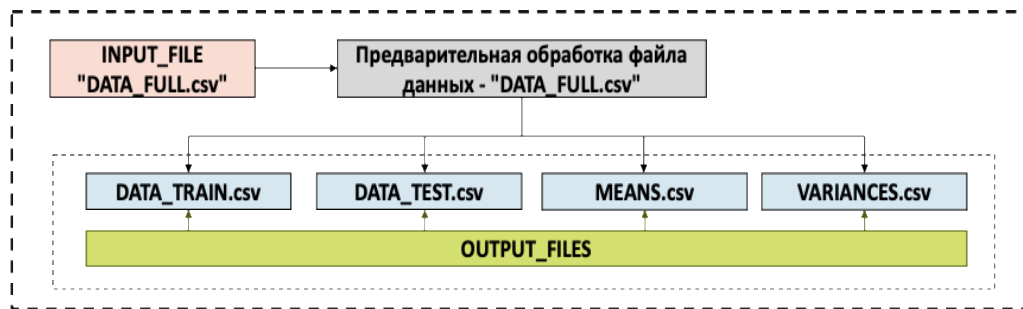


Рисунок 2. Предварительная обработка данных

Примечание – составлено авторами

После предобработки данных в соответствии с рисунком 3 осуществляется выбор информативных признаков с использованием методов фильтрации. На вход этапа поступают .csv-файлы с подготовленными наборами признаков для обучения (train) и тестирования (test). Далее применяются методы фильтрации, которые оценивают значимость каждого признака относительно целевого класса. В рамках данного исследования использованы два метода: ANOVA и Fisher, позволяющие отобрать наиболее информативные текстурные характеристики для последующего обучения моделей машинного обучения. Результатом этапа являются подмножества признаков, оптимизированные для повышения точности классификации.

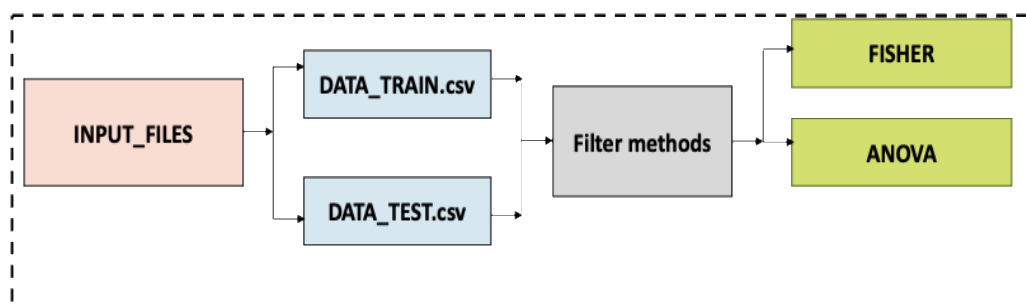


Рисунок 3. Выбор признаков с использованием методов фильтрации

Примечание – составлено авторами

Текстурный анализ МРТ-изображений

Текстурный анализ является математическим методом, позволяющим проводить оценку интенсивности сигнала на уровне серого и соседнее положение пикселей и/или

вокселей (Fritz, et al., 2018). Данный вид анализа может использоваться в МРТ для количественной оценки неоднородности компонентов ткани, превосходящей морфологический анализ (Fritz, et al., 2018). Соответственно, текстурный анализ определяет меру вариации интенсивности пикселей на данном изображении, области интереса или объеме (Michael, 2022). Таким образом, для груботекстурированных изображений будет свойственна высокая скорость изменения высокой и низкой интенсивности пикселей по сравнению с гладкотекстурированным изображением (Michael, 2022). В медицинской визуализации пространственная неоднородность внутри органа встречается при различных патологических состояниях, и повышенная неоднородность часто указывает на более агрессивное отклонение от нормы (Хорват, др., 2021).

Процесс проведения текстурного анализа включает в себя несколько последовательных этапов, таких как: 1) получение медицинских изображений в формате DICOM; 2) выбор области интереса (ROI – Region of Interest) и сегментация; 3) этап извлечения текстурных показателей; 4) статистический анализ с построением прогностических моделей с дальнейшей их оценкой. В настоящее время существуют ряд программного обеспечения (далее ПО) для выполнения текстурного анализа, в качестве примеров таких ПО можно привести MATLAB, PyRadiomics, MaZda, 3D Slicer и др.

В этапах текстурного анализа сегментация изображения может быть реализована как вручную, так и в автоматическом или полуавтоматическом режиме, с анализированием в виде 2D ROI или рассмотрением всего объема зоны интереса, а именно 3D ROI. Также необходимо отметить, что извлекаемые текстурные показатели и весь результат исследования зависят от качества изображений и сегментации. Выход за пределы ROI и включение артефактов могут привести к искажению конечных результатов. Промежуточным этапом между сегментацией и извлечением текстурных показателей является предварительная обработка изображений. Существуют различные варианты предобработки изображений, к часто встречающимся можно отнести следующие методы (Timmeren, et al., 2020): интерполяцию к изотропному вокселю; фильтрацию уровней интенсивности; дискретизацию количества и ширины ячейки (бина); применение различных фильтров, к примеру Лапласа-Гаусса, вейвлет-фильтра и др.

В процессе проведения текстурного анализа изображений полученные текстурные показатели обычно разделяют на несколько групп как показатели первого порядка и показатели второго порядка. К показателям первой группы относятся характеристики гистограммы, описывающие распределение интенсивности вокселей в изображении. Такими характеристиками являются энтропия, куртозис, значения интенсивности, скошенность, коэффициент асимметрии и однородность. Показателями второго порядка являются GLRLM (Grey-Level Run Length Matrix), GLZLM (Grey-Level Zone Length Matrix), GLCM (Grey Level Co-occurrence Matrix), NGLDM (Neighborhood Grey-Level Difference Matrix) и др. Эти показатели характеризуют взаимоотношения вокселей в ROI и отражают пространственное распределение интенсивности уровней серого в изображении. Также можно выделить показатели более высокого порядка, которые основываются на применении ряда математических функций; в качестве таких функций можно привести, к примеру вейвлет-фильтр, преобразования Фурье и др. [Parekh, et al., 2016].

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В рамках данной статьи было проведено исследование по классификации состояния мениска коленного сустава на основе текстурных признаков, извлеченных из МРТ-изображений. Предварительно изображения были обработаны в программе MaZda, где вручную выделялась область интереса (ROI), соответствующая ткани мениска. Для каждой ROI рассчитывался набор текстурных признаков, включающих статистические

характеристики гистограммы уровней серого, признаки на основе матриц совместной встречаемости уровней серого (GLCM), матриц длин серий (GLRLM), а также другие стандартные текстурные дескрипторы. Полученные признаки были экспортированы в формате .par и далее преобразованы в единую таблицу признаков с использованием Python-скрипта. Итоговый датасет содержал числовые текстурные характеристики и бинарную метку класса: 0 (normal) - здоровый мениск, 1 (tear) – горизонтальный разрыв мениска. В оценке эффективности классификации были использованы традиционные алгоритмы машинного обучения: LDA, SVM, KNN, DT, MLP и RF. С целью анализа влияния размерности признакового пространства на качество классификации была выполнена серия экспериментов с различным числом наиболее информативных признаков. Количество используемых признаков варьировалось от 2 до 16. На основе каждого набора признаков проводились обучение и валидация моделей, а качество оценивалось по метрике accuracy на валидационной выборке.

На рисунке 4 представлены результаты классификации, полученные при использовании текстурных признаков, извлеченных из МРТ-изображений мениска коленного сустава, а также различных алгоритмов машинного обучения в сочетании с методами отбора признаков ANOVA, Fisher и Recursive Feature Elimination (RFE). Исходный набор признаков включал 16 текстурных характеристик, для которых проводились последовательные эксперименты с варьированием количества отобранных признаков.

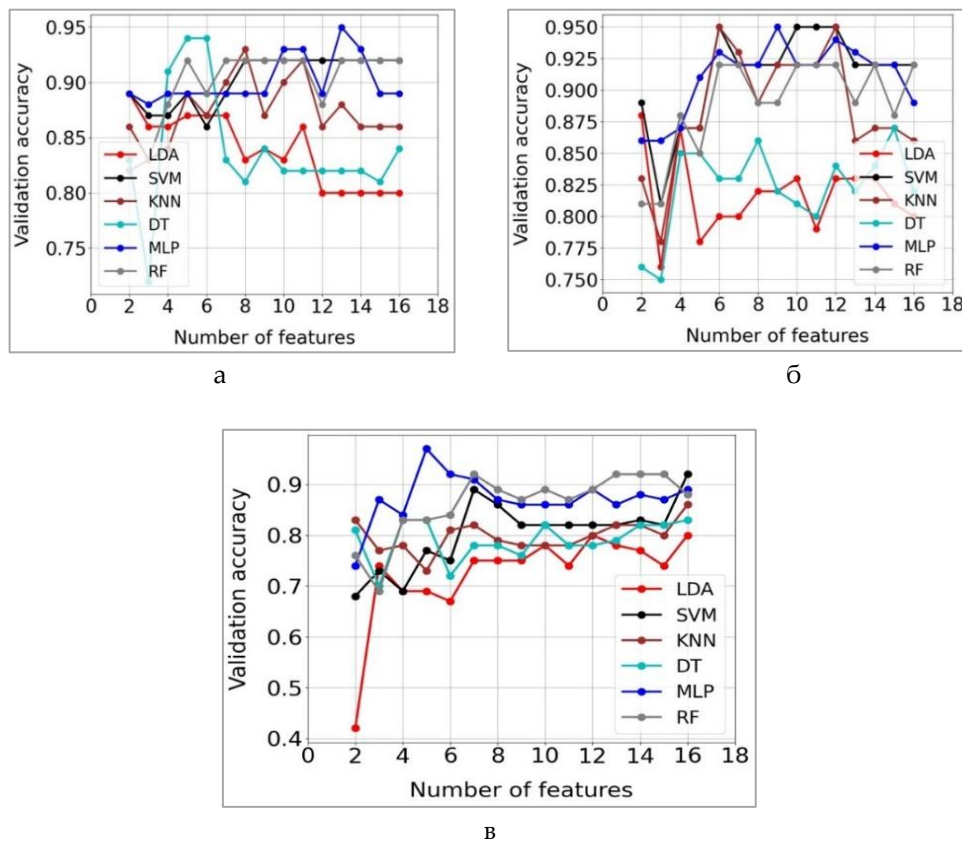


Рисунок 4. Результаты обучения и валидации моделей с использованием метода перебора по сетке для классификации по следующим методам отбора признаков: а – метод RFE; б – метод ANOVA; в – метод Фишера

Примечание – составлено авторами

Результаты эксперимента показали, что точность классификации существенно зависит как от выбранного алгоритма машинного обучения, так и от количества используемых текстурных признаков. В целом наблюдается тенденция роста качества классификации при увеличении числа признаков до определенного порогового значения, после чего точность стабилизируется либо снижается. Это указывает на наличие избыточных и коррелированных признаков в исходном наборе и подчеркивает необходимость этапа отбора признаков при анализе медицинских изображений.

В соответствии с рисунком 4(а) по методу отбора RFE наиболее устойчивые и высокие показатели точности продемонстрировали алгоритмы MLP, SVM и Random Forest. В частности, модель MLP в сочетании с методом RFE достигла максимального значения ассигасы порядка 0,95 при использовании 13 признаков, что свидетельствует о способности нейронной сети эффективно моделировать нелинейные зависимости между текстурными характеристиками мениска. Данный результат позволяет рассматривать комбинацию RFE-MLP как наиболее эффективную в рамках проведенного исследования. Алгоритм Random Forest показал стабильные результаты с точностью около 0,92, что подтверждает его устойчивость к шуму и избыточности признаков. SVM также продемонстрировал высокую и стабильную точность (до 0,93), особенно при использовании среднего и большого числа признаков, что указывает на хорошую разделимость классов в пространстве текстурных характеристик. В то же время алгоритмы LDA и DT показали более низкие значения точности и большую вариативность результатов. Это может быть связано с ограниченной способностью линейных моделей и одиночных деревьев решений описывать сложную и нелинейную структуру текстурных признаков МРТ-изображений. Метод KNN продемонстрировал умеренные показатели качества, однако его чувствительность к числу признаков и возможному шуму в данных ограничивает его практическую применимость для данной задачи. Важным наблюдением является тот факт, что увеличение числа признаков сверх определенного уровня не приводит к дальнейшему улучшению качества классификации. Это подтверждает наличие избыточных текстурных характеристик и подчеркивает целесообразность применения методов отбора признаков, таких как RFE, ANOVA и Fisher. Также на рисунке 4(б) результаты эксперимента показывают, что точность классификации значительно зависит как от алгоритма, так и от количества текстурных признаков. Наилучшие результаты демонстрируют MLP (до 0.95 точности), Random Forest и SVM, достигая максимума при использовании около 13-15 признаков, после чего дальнейшее увеличение числа признаков не улучшает качество. Более простые методы, такие как LDA и DT, показали более низкую и менее стабильную точность, что указывает на их ограниченную эффективность в моделировании сложных текстурных зависимостей. Таким образом, для данной задачи оптимальным является применение MLP, RF или SVM с тщательным отбором признаков. На рисунке 4(в) по графикам результаты показывают, что точность классификации на основе метода Фишера (Fisher Score) для отбора признаков сильно варьируется в зависимости от алгоритма. Наилучшую и наиболее стабильную точность (около 0.8-0.9) демонстрируют алгоритмы RF и SVM, причем их эффективность растет с увеличением числа признаков до 8-12, после чего стабилизируется. Метод MLP показывает высокий, но более изменчивый результат, достигая пика около 0.9, но с заметными колебаниями. Алгоритмы KNN и DT показывают умеренную точность (0.7-0.8), а LDA наименее эффективен, с точностью около 0.6-0.7, что указывает на недостаточную разделимость классов в линейном пространстве, построенном по отобраным признакам Фишера. Оптимальное число признаков для большинства методов составляет 10-14, после чего прирост точности незначителен.

В целом полученные результаты подтверждают, что текстурные признаки, извлеченные из МРТ-изображений мениска, содержат диагностически значимую

информацию, а их сочетание с современными методами машинного обучения позволяет достигать высокой точности автоматической классификации состояния мениска.

Таким образом, следующие модели достигли точности валидации 96 %: MODEL20FISHERET, MODEL8RELIEFMLP и MODEL19SBSMLP. В целом это были наиболее эффективные модели. Однако для дальнейшей работы была выбрана модель MODEL8RELIEFMLP из-за небольшого количества признаков и простоты.

На последующем этапе для каждого метода отбора признаков были выбраны наиболее эффективные модели классификации, которые были оценены на отложенном тестовом наборе для оценки их обобщающей способности. Полученные результаты подтвердили стабильность точности валидации на неизвестных данных, что указывает на отсутствие переобучения и подтверждает надежность и устойчивость предложенного подхода к построению классификаторов на основе текстурных признаков. В таблице 1 представлены наиболее эффективные модели, которые получены с применением различных алгоритмов классификации и методов отбора признаков для бинарной классификации.

Таблица 1. Оптимальные модели на основе метода отбора признаков
(бинарная классификация)

Название модели	Метод классификации	Точность валидации	Оптимальное количество признаков	Параметры моделей
MODEL2ANOVARF	RF	0,92	6-10	'clfmaxdepth': 8, 'clfnestimators': 100
MODEL1 FISHERRF	RF	0,90	6-10	'clfmaxdepth': 5, 'clfnestimators': 100
MODEL2ANOVA SVM	SVM	0,93	8-12	'clfC': 0.1, 'clfgamma': 'scale', 'clfkernell': 'linear', 'clfprobability': True}
MODEL2 FISHER SVM	SVM	0,90	8-12	'clfC': 0.1, 'clfgamma': 'scale', 'clfkernell': 'linear', 'clfprobability': True
MODEL2ANOVA MLP	MLP	0,95	13	clfactivation': 'relu', 'clfalpa': 0.0001, 'clfhiddensizes': (7), 'clfmmaxiter': 20000, 'clfsolver': 'lbfgs'
MODEL1 FISHER MLP	MLP	0,90	10-14	'clfactivation': 'relu', 'clfalpa': 0.01, 'clfhiddensizes': (1), 'clfmmaxiter': 20000, 'clfsolver': 'lbfgs'

Примечание – составлено авторами

При оценке моделей в соответствии с таблицей 2 наиболее высокие значения F1-меры (0,95) для обоих классов были достигнуты моделями MODEL2ANOVA MLP, MODEL2ANOVA SVM, что указывает на высокую точность и полноту их прогнозов.

Таблица 2. Результаты оценивания моделей

Название модели	Класс	Precision	Recall	F1-score
MODEL2ANOVARF	Class0	0.92	0.96	0.94
	Class1	0.93	0.90	0.93
MODEL1 FISHERRF	Class0	0.93	0.96	0.95
	Class1	0.94	0.92	0.94
MODEL2ANOVA SVM	Class0	0.94	0.96	0.95
	Class1	0.96	0.93	0.95
MODEL2 FISHER SVM	Class0	0.93	0.97	0.95
	Class1	0.97	0.91	0.94
MODEL2ANOVA MLP	Class0	0.95	0.97	0.95
	Class1	0.96	0.94	0.95
MODEL1 FISHER MLP	Class0	0.93	0.96	0.95
	Class1	0.94	0.93	0.94

Примечание – составлено авторами

Предложенный подход к классификации состояния мениска на основе текстурных признаков МРТ и методов машинного обучения показал высокую эффективность. Применение метода отбора признаков ANOVA позволило снизить влияние избыточных характеристик и повысить качество классификации. Согласно результатам, представленным в таблице 2, наивысшие значения F1-меры (0,95 для обоих классов) были достигнуты моделями MODEL2ANOVAMLP и MODEL2ANOVASVM, что свидетельствует о сбалансированной точности и полноте прогнозов. Полученные результаты подтверждают диагностическую значимость текстурных признаков и эффективность их сочетания с алгоритмами MLP и SVM для автоматической классификации МРТ-изображений мениска.

Предложенный метод классификации состояния мениска на основе текстурного анализа МРТ и машинного обучения показал высокую эффективность. Применение методов отбора признаков Fisher, ANOVA и RFE позволило сократить исходный набор признаков с 297 до 16, что снизило риск переобучения и повысило обобщающую способность моделей. Это особенно важно для анализа медицинских изображений, где избыточные или нерелевантные признаки могут снижать точность классификации. В таблице 3 представлен итоговый набор признаков, использованный для построения моделей ANOVAMLP и ANOVASVM для бинарной классификации классов normal и tear, упорядоченных в соответствии с ранжированием методом RFE.

Таблица 3. Набор признаков для моделей ANOVA MLP и ANOVA SVM

№	Названия признаков	Значения	
		Класс 0 (normal)	Класс 1 (tear)
1	S(0,1)Correlat	+1.000 ± 0.05	-1.000 ± 0.05
2	S(1,0)Contrast	-1.000 ± 0.05	+1.000 ± 0.05
3	Perc.01%	+1.000 ± 0.05	-1.000 ± 0.05
4	HorzlGLevNonU	-1.000 ± 0.05	+1.000 ± 0.05
5	WavEnLHs-3	+1.000 ± 0.05	-1.000 ± 0.05
6	Teta3	-1.000 ± 0.05	+1.000 ± 0.05
7	WavEnHLs-3	-1.000 ± 0.05	+1.000 ± 0.05
8	S(1,0)InvDfMom	+1.000 ± 0.05	-1.000 ± 0.05
9	Perc.10%	+1.000 ± 0.05	-1.000 ± 0.05
10	Teta1	-1.000 ± 0.05	+1.000 ± 0.05

Окончание таблицы 3

№	Названия признаков	Значения	
		Класс 0 (normal)	Класс 1 (tear)
11	S(1,0)Correlat	+1.000 ± 0.05	-1.000 ± 0.05
12	Perc.99%	-1.000 ± 0.05	+1.000 ± 0.05
13	S(1,0)AngScMom	+1.000 ± 0.05	-1.000 ± 0.05

Примечание – составлено авторами

Использование программы MaZda 4.6 обеспечило стандартизированное извлечение текстурных признаков (GLCM, GLRLM, гистограммы, вейвлет) из ROI МРТ-изображений мениска. Для бинарной классификации применялась модель ANOVAMLP и ANOVASVM на признаках, отобранных методом RFE (8–13 признаков), которая достигла точности 95 %.

ЗАКЛЮЧЕНИЕ

За последние годы применение методов машинного обучения для анализа МРТ-изображений коленного сустава стало особенно актуальным для выявления разрывов мениска, которые могут приводить к дегенерации хряща и ограничению подвижности. В данной работе использовался текстурный анализ с помощью программного обеспечения MaZda 4.6 для стандартизированного извлечения характеристик GLCM, GLRLM, гистограмм и вейвлет-признаков из ROI мениска. Для бинарной классификации классов normal и tear применялись алгоритмы MLP и SVM с отбором признаков методами RFE, ANOVA и Fisher, что позволило сократить исходный набор признаков с 297 до 16 наиболее информативных. Серия экспериментов с различным числом признаков (8–13) показала, что модели ANOVAMLP и ANOVASVM достигали точности до 95%, демонстрируя высокую стабильность и способность эффективно моделировать нелинейные зависимости между текстурными характеристиками мениска. Полученные результаты подтверждают диагностическую значимость текстурных признаков и эффективность их интеграции с современными методами машинного обучения для автоматической классификации состояния мениска.

КОНФЛИКТ ИНТЕРЕСОВ: Авторы заявляют об отсутствии конфликта интересов.

ФИНАНСИРОВАНИЕ: Данное исследование было профинансировано в рамках выполнения проекта AP23486396 «Модели и методы распознавания анатомических структур на изображениях МРТ в задачах компьютерной диагностики» 2024-2026 Министерство науки и высшего образования Республики Казахстан.

БЛАГОДАРНОСТИ: Авторы выражают благодарность анонимным рецензентам за ценные замечания, способствовавшие улучшению качества статьи.

СПИСОК ЛИТЕРАТУРЫ

- Materka, A. (2004). Texture analysis methodologies for magnetic resonance imaging. *Dialogues in Clinical Neuroscience*, 6(2), 243–250. <https://doi.org/10.31887/DCNS.2004.6.2/amaterka>
- Aoki, T., et al. (2018). Comparison verification between texture analysis based on T2map MRI and histological analysis of the meniscal degeneration in patients with knee osteoarthritis. *Osteoarthritis and Cartilage*, 26, S413.
- Juras, V., Szomolanyi, P., Janáčová, V., Kirner, A., Angele, P., & Trattng, S. (2021). Differentiation of cartilage repair techniques using texture analysis from T2 maps. *Cartilage*, 13(1suppl), 718S–728S. <https://doi.org/10.1177/19476035211029698>
- Janacova, V., Szomolanyi, P., Kirner, A., et al. (2022). Adjacent cartilage tissue structure after successful transplantation: a quantitative MRI study using T2 mapping and texture analysis. *European Radiology*, 32, 8364–8375. <https://doi.org/10.1007/s00330-022-08897-y>

- Janacova, V., Juras, V., Szomolanyi, P., & Trattnig, S. (2021). Optimization of knee cartilage texture analysis of quantitative MRI T2 maps. *Osteoarthritis and Cartilage*, 29, S329–S330. <https://doi.org/10.1016/j.joca.2021.02.430>
- Fischer, M. A. (2022). From morphology to biomarker: quantitative texture analysis of the infrapatellar fat pad reliably predicts knee osteoarthritis. *Radiology*, 304(3), 622–623. <https://doi.org/10.1148/radiol.22109>
- van Timmeren, J. E., Cester, D., Tanadini-Lang, S., et al. (2020). Radiomics in medical imaging— "how-to" guide and critical reflection. *Insights into Imaging*, 11, 91. <https://doi.org/10.1186/s13244-020-00887-2>
- Parekh, V., & Jacobs, M. A. (2016). Radiomics: a new application from established techniques. *Expert Review of Precision Medicine and Drug Development*, 1(2), 207–226. <https://doi.org/10.1080/23808993.2016.1164013>
- Tlebaldinova, A., Omiotek, Z., Karmenova, M., Kumargazhanova, S., Smailova, S., Tankibayeva, A., Kumarkanova, A., & Glinskiy, I. (2025). Comparison of modern convolution and transformer architectures: YOLO and RT-DETR in meniscus diagnosis. *Computers*, 14, 333. <https://doi.org/10.3390/computers14080333>
- Kazantsev, I. G., Tankibayeva, A. K., Kumargazhanova, S. K., & Azamatov, B. N. (2024). Correction of intensity inhomogeneity in magnetic resonance images using ramp filter. *Sibirsk. Elektron. Mat. Izv.*, 21(1), 307–314. <https://doi.org/10.33048/semi.2024.21.023>
- Фриц, Б., Мюллер, Д.А., Саттер, Р. и др. (2018). Магнитно-резонансная симография сортирование хрящевых опухолей костей: добавленная стоимость количественной текстуры анализ. *Invest Radiol*, 53(11), 663–672. // Fritz, B., Müller, D. A., Sutter, R., et al. (2018). Magnitno-rezonansnaya simografiya sortirovanie khryashchevykh opukholey kostey: dobavlennoy stoimost' kolichestvennoy tekstury analiz [Magnetic resonance imaging for sorting cartilage bone tumors: added value of quantitative texture analysis]. *Invest Radiol*, 53(11), 663–672. (In Russ.)
- Хорват, Н., Миранда, Дж., Хомси, М.Э. и др. (2021). Праймер по анализу текстуры в абдоминальной радиологии. *Abdom Radiol (New York)*. <https://doi.org/10.1007/s00261-021-03359-3> // Horvat, N., Miranda, J., Homsy, M. E., et al. (2021). Praimer po analizu tekstury v abdominal'naya radiologiya [Primer on texture analysis in abdominal radiology]. *Abdom Radiol (New York)*. (In Russ.)
- Тлебадинова, А.С., Карменова, М.А., Кумаргажанова, С.К., Смаилова, С.С. (2025). Разведочный анализ МРТ изображений для улучшения качества медицинской визуализации и диагностики. *Труды университета Карту*, 2(99), 378–385. <https://doi.org/10.52209/1609-182520252378> // Tlebaldinova, A.S., Karmenova, M.A., Kumargazhanova, S.K., Smailova, S.S. (2025). Razvedochnyy analiz MRT izobrazheniy dlya uluchsheniya kachestva meditsinskoy vizualizatsii i diagnostiki [Exploratory analysis of MRI images to improve medical visualization and diagnostics]. *Trudy Universiteta KartU*, 2(99), 378–385. (In Russ.)
- Құмарқанова, А.С., Тлебадинова, А.С., Танкибаева, А.К., Карменова, М.А., Кумаргажанова, С.К. (2025). Сүзгілеу және сапаны бағалау негізінде МРТ кескіндерін өңдеудің кешенді тәсілі. *Вестник ВКТУ*, 2(99), 153–162. <https://doi.org/10.51885/1561-421220252153> // Qumarkanova, A.S., Tlebaldinova, A.S., Tankibayeva, A.K., Karmenova, M.A., Kumargazhanova, S. K. (2025). Süzğileu jáne sapany bağalau negizinde MRT keskinderin öndewdiń kesendi tásili [Comprehensive MRI image processing approach based on filtering and quality assessment]. *Vestnik VKTU*, 2(99), 153–162. (In Kaz.)
- Сыдыкова, А.М., Женис, С.М., Кумаргажанова, С.К., Тлебадинова, А.С., Нурсадыкова, Р.К. (2025). Автоматическая классификация стадий эмбрионального развития на основе методов машинного обучения. *Вестник Университета Шакарима. Серия технические науки*, 2(18), 128–137. [https://doi.org/10.53360/2788-7995-2025-2\(18\)-15](https://doi.org/10.53360/2788-7995-2025-2(18)-15) // Sydykova, A. M.,

Zhenis, S.M., Kumargazhanova, S.K., Tlebaldinova, A.S., Nursadykova, R.K. (2025). Avtomaticheskaya klassifikatsiya stadiy embrional'nogo razvitiya na osnove metodov mashinnogo obucheniya [Automatic classification of embryonic development stages using machine learning methods]. Vestnik Universiteta Shakarima. Seriya tekhnicheskie nauki, 2(18), 128–137. (In Russ.)

Авторлар туралы мәліметтер
Информация об авторах
Information about authors



Карменова Мархаба Ахметоллиновна – PhD, С. Аманжолова атындағы Шығыс Қазақстан университеті, Өскемен қ., Қазақстан

Карменова Мархаба Ахметоллиновна – PhD, Восточно-Казахстанский университет им. С. Аманжолова, г. Усть-Каменогорск, Казахстан

Karmenova Marhaba Akhmetollinovna – PhD, S. Amanzholov East Kazakhstan University, Oskemen, Kazakhstan

e-mail: mkarmenova@vku.edu.kz

ORCID: <https://orcid.org/0000-0002-3028-9461>



Төлеуғазы Зере Мейрамбекқызы – оқушы, Назарбаев Зияткерлік мектептері автономды білім беру ұйымының Өскемен қалалық жаратылыстану ғылымдары және математика бағытындағы Назарбаев Зияткерлік мектебінің филиалы, Өскемен, Қазақстан

Төлеуғазы Зере Мейрамбекқызы – ученица, Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

Toleugazy Zere – student, Branch of the Nazarbayev Intellectual School of Natural Sciences and Mathematics of the City of Ust-Kamenogorsk of the Autonomous Educational Organization Nazarbayev Intellectual Schools, Ust-Kamenogorsk, Kazakhstan

e-mail: zeretoleugazy@gmail.com,

ORCID: <https://orcid.org/0009-0007-3682-3665>



Дуанбаева Толқын Бақытбекқызы – магистр, Назарбаев Зияткерлік мектептері автономды білім беру ұйымының Өскемен қалалық жаратылыстану ғылымдары және математика бағытындағы Назарбаев Зияткерлік мектебінің филиалы, Өскемен, Қазақстан

Дуанбаева Толқын Бақытбекқызы – магистр, Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

Duanbaeva Tolkyn Bakytbekkyzy – master, Branch of the Nazarbayev Intellectual School of Natural Sciences and Mathematics of the City of Ust-Kamenogorsk of the Autonomous Educational Organization Nazarbayev Intellectual Schools, Ust-Kamenogorsk, Kazakhstan

e-mail: duanbaevat@ukk.nis.edu.kz,

ORCID: <https://orcid.org/0009-0003-0392-6642>



Тлебалдинова Айжан Солтанғалиевна – PhD, қауымдастырылған профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

Tlebaldinova Aizhan Soltangieliyevna – PhD, ассоциированный профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

Tlebaldinova Aizhan – PhD, Associate Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan

e-mail: atlebaldinova@edu.ektu.kz,

ORCID: <https://orcid.org/0000-0003-1271-0352>



Құмарғажанвоа Сәуле Құмарғажановна – т.ғ.к., профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

Кумаргажанова Сауле Кумаргажановна – кандидат технических наук, профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

Kumargazhanova Saule – Candidate of Technical Sciences, Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan,

e-mail: saule.kumargazhanova@edu.ektu.kz,

ORCID: <https://orcid.org/0000-0002-6744-4023>



Omiotek Zbigniew – dr hab. inż., қауымдастырылған профессор, Электротехника және информатика факультетінің доценті, Люблин технологиялық университеті, Люблин, Польша

Omiotek Zbigniew – dr hab. inż., ассоциированный профессор, Факультет электротехники и информатики, Люблинский технический университет, г. Люблин, Польша

Omiotek Zbigniew – doctor habilitatus of engineering (Dr hab. inż.), associate professor, Faculty of Electrical Engineering and Computer Science, Lublin University of Technology, Lublin, Poland

e-mail: z.omiotek@pollub.pl,

ORCID: <https://orcid.org/0000-0002-6614-7799>