

ДИАГНОСТИКА МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ ОПУХОЛЕЙ МОЛОЧНОЙ ЖЕЛЕЗЫ С ИСПОЛЬЗОВАНИЕМ ГИБРИДНЫХ СВЕРТОЧНЫХ НЕЧЕТКИХ НЕЙРОННЫХ СЕТЕЙ

Галиб Гамидов, Юрий. П. Зайченко

Резюме: Рассмотрена проблема классификации опухолей молочной железы по медицинским изображениям. Для ее решения разработана гибридная нечеткая сеть CNN, в которой сверточная нейронная сеть используется в качестве экстрактора признаков, а нечеткая нейронная сеть NEFClass используется в качестве классификатора. Разработаны и внедрены алгоритмы обучения FNN. Проведены экспериментальные исследования предложенной гибридной сети на стандартном наборе данных BreakHis и проведено сравнение с известными результатами. Рассмотрена проблема уменьшения размерности данных и исследовано применение метода ИКМ.

Keywords: medical diagnostics, breast cancer classification, FNN, CNN, hybrid network

ITHEA Keywords: 1. Computing methodologies 12. Artificial intelligence, 16.5. Model development

Введение. Анализ состояния проблемы

В настоящее время заболевания раком представляют огромную проблему для системы здравоохранения во всем мире [Boyle, 2012]. Среди различных типов рака рак молочной железы занимает второе место по частоте у женщин. Кроме того, смертность от него очень высока в сравнении с другими раковыми заболеваниями.

В настоящее время в практике медицинской диагностики широко используются информационные технологии. Основная цель медицинских информационных систем - расширение сферы практических задач, которые

можно решать с помощью компьютеров, повышение интеллектуального уровня поддержки принимаемых решений в сфере медицинской диагностики на основе обработки и анализа медицинских изображений тканей органов человека с применением различных источников (МРТ, КТ, рентгеновские снимки и т.п.)

Преимуществами систем медицинской диагностики являются скорость и стабильность работы, которые делают их удобным средством экспресс-анализа. Несмотря на юный возраст медицинской информатики, который не превышает 30 лет, информационные технологии быстро проникают в различные сферы медицины и охраны здоровья (семейная медицина, страховая медицина создание единого информационного пространства в медицине и т.д.). Несмотря на очевидный прогресс, достигнутый системами медицинской диагностики, окончательный диагноз рака молочной железы, включая классификацию опухолей выполняется паталого-анатомами которые используют визуальный анализ гистопатологических образцов под микроскопом.

В медицинской диагностике большую часть проблемы представляет извлечение признаков для последующей обработки изображений и их классификации. С развитием и широким распространением СППР в медицине повышаются требования к алгоритмам обучения таких систем.

Последние достижения в технологиях обработки изображений и машинном обучении позволяют создавать системы автоматического обнаружения и к опухолям, которые классификации могут помочь паталого-анатому делать правильный диагноз и ускорить его работу. Классификация изображений на различных паттернах, которые соответствуют раковым и нераковым состояниям тканей часто является первостепенной целью автоматической диагностики рака молочной железы.

На данный момент имеется несколько моделей и методов для обнаружения рака молочной железы, которые используют различные алгоритмы обучения. Используя методы и технологии ИИ, такие, как нейронные сети и метод опорных векторов в работах [Lakhani, 2012],

[Zhang, 2013] была достигнута точность классификации опухолей от 74 до 94% на наборе данных из 92 изображений.

Большинство последних работ относящихся к области классификации рака молочной железы ориентированы на цифровые изображения. (WSI) [Zhang, 2013], [Zhang, 2014], [Doyle, 2008], [Singh]. Однако широкое применение систем автоматической классификации рака молочной железы наталкивается на такие проблемы, как высокая стоимость реализации, недостаточная производительность для большого объема данных и противодействия со стороны патолого-анатомов (человеческий фактор). До настоящего времени большинство работ, основанных на гистологическом анализе, выполнялись на небольших дата-сетах.

Существенным сдвигом в этом направлении является создание датасета, состоящего из 7909 изображений молочной железы, полученных от 82 пациентов [Spanhol, 2016]. На этом датасете авторы оценивали различные текстурные дескрипторы и классификаторы и провели эксперименты и достигли точности от 82% до 85%.

На протяжении многих лет основным средством получения признаков изображений для последующей классификации являлись текстурные дескрипторы. Однако недостаток их использования состоит в отсутствии универсальности, в следствие чего, что для каждого типа изображений необходимо разрабатывать свои дескрипторы. Другой подход базируется на системах машинного обучения презентациям. Этот подход не нов, но стал реализуем только с появлением графических процессоров GPU (Graphic Processing Units), которые способны обеспечить сверхвысокую производительность с относительно низкой стоимостью, благодаря параллельной архитектуре [Bengio, 2013].

Альтернативой к этим подходам является использование сверточных сетей (CNN) для обработки медицинских изображений и диагностики. В ряде работ было показано, что сверточные сети способны превзойти обычные текстурные дескрипторы [LeCun, 2015], [Krizhevsky, 2012]. Кроме того, традиционный подход к выделению признаков на основе дескрипторов требует больших усилий и высокого уровня знаний

экспертов и обычно является специфичным для каждой задачи, что препятствует его непосредственное применение к другим задачам.

Поэтому в настоящей статье предлагается новая гибридная сверточная нечеткая сеть CNN- FNN, в которой CNN используется для выделения признаков на медицинских, а нечеткая нейронная сеть FNN используется для классификации обнаруженных опухолей на изображениях на два класса: доброкачественные и злокачественные.

Основная цель настоящей работы состоит в разработке и исследовании гибридной сети CNN-FNN и исследовании ее эффективности в задаче распознавания медицинских изображений молочной железы и классификации опухолей, а также сравнении ее эффективности с известными работами на стандартном датасете медицинских изображений [Spanhol, 2016].

Описание базы медицинских данных

Датасет медицинских данных BreakHis [Spanhol, 2016] содержит данные биопсии доброкачественных и злокачественных опухолей тканей молочной железы. Изображения были получены в результате клинических исследований с января по декабрь 2014. Датасет медицинских данных BreakHis состоит из 7909 клинически представительных изображений под микроскопом опухолей молочной железы от 82 пациентов с различным масштабом увеличения 40X, 100X, 200X, and 400X. Все пациенты, которые в течение этого периода исследовались в медицинской лаборатории, были приглашены принять участие в исследовании. Все данные являлись анонимными. Образцы генерировались путем хирургических срезов опухоли молочной железы, специально раскрашивались и отмечались патолого-анатомом.

Основная цель -сохранить оригинальную структуру опухоли и ее молекулярный состав, что позволит наблюдать ее под оптическим микроскопом. Для исследований все образцы разрезались на слайды размером 3 мкм.

Окончательный диагноз каждого случая делался опытным патолого-анатомом, который затем подтверждался дополнительным исследованием, таким как иммунная гистология.

В исследованиях использовался микроскоп системы Olympus BX-50 с увеличением 3.3, связанный с цифровой камерой Samsung SCC-131AN, которая использовалась для получения цифровых изображений молочной железы. Изображения получались в 3 каналах (8-битные каналы RGB) с коэффициентами увеличения 40X, 100X, 200X, and 400X.

На рис. 1-4 представлены 4 изображения с соответствующими коэффициентами увеличения: (a) 40 ×, (b) 100 ×, (c) 200 × и (d) 400 × - полученными из одного слайда ткани молочной железы, содержащего злокачественную опухоль (breast cancer). Выделенный прямоугольник-регион интереса (ROI), который выбирается патолого-анатомом и будет описан в следующем разделе.

В настоящий момент датасет BreakHis содержит 7909 изображений, разбитых на доброкачественные и злокачественные опухоли.

В табл.1 представлено распределение изображений датасета BreakHis [Spanhol, 2016].

Таблица 1. Распределение изображений по классам и коэффициентам усиления

Коэффициент усиления	Доброкачественные	Злокачественные	Всего образцов
40x	625	1370	1995
100x	644	1437	2081
200x	623	1390	2013
400x	588	1232	1820
Total	2480	5429	7909
Число пациентов:	24	58	82




Рис. 1. Слайд злокачественной опухоли с коэффициентом 40X




Рис. 2. Слайд злокачественной опухоли с коэффициентом 100X




Рис. 3. Слайд злокачественной опухоли с коэффициентом 200X




Рис. 4. Слайд злокачественной опухоли с коэффициентом 400X




Рис. 5. Слайд доброкачественной опухоли с коэффициентом 100X

Сверточные нейронные сети (краткое описание)

Сверточные сети (CNN) – современный метод, широко используемый для обработки изображений. Они обладают способностью извлекать глобальные признаки изображения в иерархическом виде. CNN включает следующие слои [Krizhevsky, 2012].

- **Сверточный слой.** Он рассматривается как основной рабочий компонент сверточной сети и играет жизненно важную роль в этой сети. Ядро свертки (фильтр), обычно представляющий матрицу $n \times n$, последовательно проходит по всем пикселям изображения и выделяет информацию из него путем операции свертки.
- **Шаги (Stride) и дополнение (Padding).** Матрица фильтра (ядро) движется по изображению с шагом **Stride**, определяемым его размером, по умолчанию его размер принимается равным 1. Если размер изображения 5×5 сканируется фильтром размером 3×3 и шагом 1, то мы получим после свертки выходную матрицу 3×3 . Однако если мы используем шаг 2, то выходное изображение будет размером 2×2 .

Таким образом размер выходного изображения определяется размерами фильтра(ядра) и шага. Чтобы обойти это явление, можно дополнить исходное изображение столбцами и строками, содержащими 0 (Padding). В таком случае размер выходного изображения после свертки будет равным исходному. Такое добавление строк и столбцов, содержащих только 0, называется *zero padding* [Krizhevsky, 2012].

- **Нелинейное преобразование (Nonlinear Performance).** Каждый слой нейронной сети(NN) дает линейный выход и добавление двух таких слоев также осуществляет линейное преобразование. Поэтому увеличение числа слоев нейронной сети не изменяет характера сети. Для преодоления этого недостатка используется нелинейное преобразование в виде следующих функций:
- Rectified Linear Unit (ReLU), Leaky ReLU, TanH, Sigmoid, и т.д.
- Операция пулинга (**Pooling Operation**). Сверточная нейронная сеть производит большой объем информации. Поэтому чтобы уменьшить размерность пространства признаков, используется операция пулинг. Известны несколько стандартных операций пулинга такие, как MaxPooling, AveragePooling.

В нашей работе используется операция MaxPooling, которая выбирает максимальное значение из некоторой подматрицы после свертки.

- Операция **Drop-Out**.
В результате обучения сети возможно явление переобучения на тестовой выборке, известное как over-fitting. Это явление можно устранить, используя процедуру дропаут (Drop-Out), которая состоит в выключении некоторых нейронов из сети при обучении.
- Решающий слой **Decision Layer**. Для классификации изображений на конце сверточной сети используется решающий слой, обычно в виде многослойного перцептрона (usually MLP). С этой целью используется слой Softmax layer или слой метода опорных векторов (SVM layer). Этот слой реализует нормализованную экспоненциальную функцию и подсчитывает функцию потерь (loss function) для данных классификации.

CNN модель для классификации изображений

На рис. 6 приведена архитектура сверточной сети VGG-16, которая используется в нашей работе в качестве детектора информативных признаков изображения. Она обучалась различными алгоритмами: стохастическим градиентным методом, методом дифференциальной эволюции (SCD) [Zaychenko, 2009], [Zgurovsky, 2016] и алгоритмом basin hopping [Olson, 2012].

В качестве классификатора полученных признаков в данной работе предложено использовать нечеткую нейронную сеть FNN NEFClass в отличие от известных работ, в которых применялся многослойный перцептрон и слой машины опорных векторов (SVM).

FNN NEFClass была первоначально предложена Д. Науком и В. Крузе (W. Kruse) в [Nauck, 1997]. Она была модифицирована и развита в работах [Zaychenko, 2004], [Zaychenko, 2009] (так называемая FNN NEFClass M). Для нее были разработаны алгоритмы обучения: градиентного спуска, сопряженных градиентов и генетический алгоритм [Zaychenko, 2009] и использованы для распознавания оптических изображений, полученных с использованием мультиспектральной системы.

ННС NEFCLASS M была ранее успешно применена для анализа и распознавания медицинских изображений шейки матки и диагностики опухолей [Zaychenko, 2015]. Основное преимущество ННС NEFClass — это возможность работы с неполными и нечеткими входными данными и осуществлять нечеткую классификацию входных изображений, используя функции принадлежности; высокая скорость и точность классификации. [Zaychenko, 2009], [Zgurovsky, 2016] в сравнении с традиционными методами классификации.




Рис.6. Сверточная нейронная сеть VGG-16

Экспериментальные исследования и анализ полученных результатов

Как уже указывалось, в данном исследовании было использовано предварительное обучение сверточной сети CNN VGG 16. Существует два основных сценария обучения НС.

Извлечение признаков. В этом случае полносвязные слои отключаются, а оставшаяся часть сети используется как экстрактор признаков в новых данных (датасетах).

Тонкая настройка. В таком случае новый датасет используется для тонкой настройки предварительно обученной НС.

В настоящем исследовании сеть CNN VGG- 16 была использована для извлечения признаков в медицинских изображениях опухолей молочной железы. После этого найденные признаки подавались на вход ННС

NEFClass. Для обучения использовались 3 алгоритма: basin hopping, стохастический градиентный спуск (СГС) и дифференциальная эволюция (differential evolution) [Zgurovsky, 2016].

Были проведены серии экспериментов и сравнение с результатами предшествующих работ.

В следующих таблицах 2, 3 приводятся результаты классификации с различными параметрами. Все образцы были разбиты на обучающую и тестовую подвыборки в соотношении 80% / 20%.

В первом эксперименте варьировалось число лингвистических переменных и число правил целью определения оптимальных параметров (табл.2).

Таблица 2. Результаты классификации FNN NEFClass

Число нечетких множеств (лингвистических переменных)/ число правил	40X	100X	200X	400X
A	73%	74%	74.2%	73.5%
4,2	75.3%	74.8%	75.7%	75.4%
6,2	78.2%	79%	78.4%	78%
8,2	76%	75.4%	76.5%	75.8%
2,4	75%	74%	73.8%	73%
4,4	78.3%	76.3%	75.7%	75.4%
6,4	82%	83%	82.4%	83.2%
8,4	82.2%	81.5%	81.5%	83.8%

Число нечетких множеств (лингвистических переменных)/ число правил	40X	100X	200X	400X
2,6	75.4%	73.8%	74.4%	73.2%
4,6	90%	91%	90.5%	90%
6,6	89%	89.7%	90.2%	89.5%
8,6	90.3%	90.5%	92%	91.2%
4,8	89.3%	89.8%	89.7%	89.3%
6,8	89.2%	88%	89.4%	88.4%
8,8	88%	87.2%	87.2%	87%

Из анализа этой таблицы следует, что начиная с 6 нечетких множеств на переменную и 6 правил вывода, точность перестает повышаться, а сложность обучения растет. Как следует из этой таблицы, оптимальные значения параметров – 4 нечетких множества (на переменную) и 6 правил.

Для сравнения эффективности предложенной гибридной сверточной сети представим результаты предшествующей работы, полученные с помощью других классификаторов: линейной и полиномиальной машин опорных векторов (SVM) и метода Random forest [Singh,] (см. табл.3)

Таблица 3. Сравнение точности различных классификаторов

классификатор/ коэффициент усиления	40X	100X	200X	400X
Линейная SVM	89%	89%	88%	88%
Полиномиальная SVM	88%	90%	89%	85%
Random forest	89.18%	88%	87.74%	80%
NEFClass	90%	91%	90.5%	90%

Как легко можно видеть из табл.3, ННС NEFClass показывает лучшие результаты, чем альтернативные классификаторы.

В данной работе были применены и исследованы три алгоритма обучения FNN NEFClass: *baisin hopping* [Olson, 2012], стохастический градиентный спуск (СГС) и дифференциальная эволюция [Zaychenko, 2009]. Как показали эксперименты, алгоритмы *baisin hopping* и СГС (*stochastic gradient descent*) дают примерно одинаково хорошие результаты, а алгоритм дифференциальной эволюции оказался значительно хуже.

Следует заметить, что в данной проблеме число признаков, извлекаемых сетью CNN VGG-16, оказалось очень большим – 4096 (проблема Big Data). Поэтому была поставлена задача сокращения числа признаков. Для этих целей был применен метод главных компонент (ГК) [Jindal, 2013]. В таблице 4 представлены результаты такого сокращения признаков.

Таблица 4. Зависимость величины общей вариации от числа главных компонент и примерное время обучения

Число главных компонент	Нормированная общая вариация (дисперсия)	Примерное время обучения (час)
100	0.840587442159	~2 час
200	0.897366730496	~3 час
250	0.912324353994	~4 час
500	0.954868534936	~9 час

Из табл.4 следует, что наиболее приемлемым является сокращение числа главных компонент до 250.

Вследствие лимита времени последующие эксперименты проводились с коэффициентом усиления (magnificence factor) 100X (2081 образцов).

В Таблице 5. приводится точность классификации для различных варьируемых параметров ННС NEFClass.

Таблица 5. Точность классификации для 250 признаков

Число нечетких множеств / число правил	100X
4/4	80.64%
4/6	87.24%
4/8	88.18%

В таблице 6 приводится зависимость точности классификации от числа признаков. Легко можно видеть, что точность при сокращении числа признаков до 250 (примерно 16 раз) точность уменьшилась на несколько процентов, но при этом существенно сократилось время обучения.

Таблица 6. Точность классификации с разным числом признаков

Число нечетких множеств, число правил /число признаков	100	250	4096
4,4	75.23%	80.64%	86.3%
4,6	83.34%	87.24%	91%
4,8	84.21%	88.18%	89.8%

Из данной таблицы можно видеть, что точность с уменьшением числа признаков падает всего на 3-5%, если сравнивать 100 и 250 признаков. Для сравнения была проведена классификация с полным набором 4096 признаков и было установлено, что с уменьшением числа признаков в 16 раз точность упала всего, в среднем на 3-5%.

Это свидетельствует об эффективности применения метода главных компонент для сокращения числа признаков в задачах классификации медицинских изображений.

Выводы

- 1 Рассмотрена проблема анализа медицинских изображений молочной железы и классификации обнаруженных опухолей на два класса: доброкачественные и злокачественные.
- 2 Для распознавания опухолей была разработана гибридная сверточная нечеткая сеть CNN- FNN, в которой CNN VGG 16 была

использована для выделения признаков на изображениях, а ННС NEFClass– для классификации обнаруженных опухолей на основе этих признаков.

- 3 Для обучения ННСNEFClass были предложены и реализованы алгоритмы обучения baissin hopping, стохастический градиентный спуск (СГС) и дифференциальная эволюция.
- 4 Проведены экспериментальные исследования предложенной гибридной CNN-FNN сети в задаче классификации реальных изображений на специальном датасете BreakHis.
- 5 Сравнение точности классификации предложенной гибридной CNN-FNN сети с известными результатами для сверточной сети с алгоритмами классификации SVM и Random forest показало целесообразность использования гибридной сети.
- 6 Рассмотрена и проанализирована проблема снижения размерности признаков в задачах классификации медицинских изображений с использованием метода главных компонент и оценена его эффективность.

Библиография

- [Boyle, 2012] P. Boyle and B. Levin, Eds., World Cancer Report 2012. Lyon: IARC, 2012. [Online]. Available:http://www.iarc.fr/en/publications/pdfs-online/wcr/2008/wcr_2012.pdf
- [Lakhani, 2012] S. R. Lakhani, E. I.O., S. Schnitt, P. Tan, and M. van de Vijver, WHO classification of tumours of the breast, 4th ed. Lyon: WHO Press,2012.
- [Zhang, 2013] Y. Zhang, B. Zhang, F. Coenen, and W. Lu, “Breast cancer diagnosis from biopsy images with highly reliable random subspace classifier ensembles,” Machine Vision and Applications, vol. 24, no. 7, pp. 1405–1420,2013.
- [Zhang, 2014] Y. Zhang, B. Zhang, F. Coenen, J. Xiau, and W. Lu, “One-class kernel subspace ensemble for medical image classification,” EURASIP Journal on Advances in Signal Processing, vol. 2014, no. 17, pp. 1–13,2014.

- [Doyle, 2008] S. Doyle, S. Agner, A. Madabhushi, M. Feldman, and J.Tomaszewski, “Automated grading of breast cancer histopathology using spectral clustering with textural and architectural image features,” in Proceedings of the 5th IEEE International Symposium on Biomedical Imaging (ISBI): From Nano to Macro, vol. 61. IEEE, May 2008, pp.496–499.
- [Singh,] Aditi Singh, Hadi Mansourifar, Hasnain Bilgrami, Nikhil Makkar, Tanay Shah. Classifying Biological Images Using Pre-trained CNNs. <https://docs.google.com/document/d/1H7xVK7nwXcv11CYh7hl5F6pM0m218FQloAXQODP-Hsg/edit?usp=sharing>
- [Spanhol, 2016] F. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, “A dataset for breast cancer histopathological image classification,” IEEE Transactions of Biomedical Engineering, 2016.
- [Bengio, 2013] Y. Bengio, A. Courville, and P. Vincent, “Representation learning:A review and new perspectives,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, pp. 1798–1828,2013.
- [LeCun, 2015] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” Nature, vol. 521, pp. 436–444, 2015.
- [Krizhevsky, 2012] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in Advances in NeuralInformation Processing Systems 25, 2012, pp.1097–1105.
- [Olson, 2012] Olson,B.,Hashmi,I.,Molloy,K.,andShehu1,A.,Basin Hopping as a General and Versatile Optimization Framework for the Characterization of Biological Macromolecules, Advances in Artificial Intelligence, Volume 2012 (2012), Article ID674832.
- [Nauck, 1997] Detlef Nauck and Rudolf Kruse. New learning strategies for NEFCLASS. In Proc. Seventh International Fuzzy Systems Association World Congress IFSA’97, Vol. IV, pp. 50-55, Academia Prague, 1997.
- [Zaychenko, 2004] Zaychenko Yu. P. , Sevae Fatma, Matsak A.V. Fuzzy neural networks for economic data classification// Vestnik of National Technical University of Ukraine “KPI”, section “Informatic, control and computer engineering. Vol. 42.-2004.-pp.121-133. (rus)

- [Zaychenko, 2009] Zaychenko Yu.P. , Petrosyuk I.M., Jaroshenko M.S. The investigations of fuzzy neural networks in the problems of electro-optical images recognition// System research and information technologies. -2009.- №4.- pp. 61-76. (rus).
- [Zgurovsky, 2016] M. Zgurovsky, Yu. Zaychenko. The Fundamentals of Computational Intelligence: System Approach. Springer International Publishing AG, Switzerland.-2016.-308p.
- [Zaychenko, 2015] Yuriy Zaychenko, Vira Huskova. Recognition of objects on Optical Images in Medical Diagnostics Using Fuzzy Neural Network NEFClass. Intern. Journal Information Models and Analysis, 2015. Vol .4, Number 1, pp. 13-22.
- [Jindal, 2013] N. Jindal. Enhanced Face Recognition Algorithm using PCA with Artificial Neural Networks. / N Jindal, V Kumar // International Journal of Advanced Research in Computer Science and Software Engineering.– 2013. – Vol. 3, pp. 864-872.

Информация об авторах



Yuri Zaychenko – Professor, doctor of technical sciences, Institute for applied system analysis, NTUU “KPI”, 03056, Ukraine, Kyiv, Peremogi pr. 37, Corpus 35; e-mail: baskervil@voliacable.com, zaychenkoyuri@ukr.net

Major Fields of Scientific Research: Information systems, Fuzzy logic, Decision making theory



Galib Hamidov- PhD, doctor philosophy of technical sciences, “Bakielektrikshebeke” JSC, Head of the Information technologies department, AZ 1065, Azerbaijan, Baku, Kazimzade st. 20, e- mail: galib.hamidov@gmail.com

Major Fields of Scientific Research: Information technologies, Data Mining

Medical Images of Breast Tumor Diagnostics with Application of Hybrid Fuzzy Convolutional Networks

Galib Hamidov, Yuriy Zaychenko

Abstract: *The problem of classification of breast tumors on medical images is considered. For its solution hybrid fuzzy CNN network is developed in which convolutional neural network is used as feature extractor while fuzzy neural network NEFClass is used as classifier. Training algorithms of FNN were developed and implemented. The experimental investigations of the suggested hybrid network on the standard data set BreakHis were carried out and comparison with known results was performed. The problem of data dimensionality reduction is considered and application of PCM method is investigated.*

Keywords: *medical diagnostics, breast cancer classification, FNN, CNN, hybrid network*

ITHEA Keywords: *1. Computing methodologies 12. Artificial intelligence, 16.5. Model development*