

**O‘ZBEKISTON RESPUBLIKASI OLIY TA’LIM, FAN VA
INNOVATSIYALAR VAZIRLIGI**

**MIRZO ULUG‘BEK NOMIDAGI O‘ZBEKISTON MILLIY
UNIVERSITETINING JIZZAX FILIALI**



KOMPYUTER ILMLARI VA MUHANDISLIK TEXNOLOGIYALARI
mavzusidagi Xalqaro ilmiy-texnik anjuman materiallari to‘plami
2026-yil 25-26-sentabr

(1-qism)

JIZZAX-2026

Kompyuter ilmlari va muhandislik texnologiyalari. Xalqaro ilmiy-texnik anjuman materiallari to'plami – Jizzax: O'zMU Jizzax filiali, 2026-yil 25-26-sentabr. 507-bet.

Xalqaro miqyosidagi ilmiy-texnik anjuman materiallarida zamonaviy kompyuter ilmlari va muhandislik texnologiyalari sohasidagi innovatsion tadqiqotlar aks etgan.

Globalashuv sharoitida davlatimizni yanada barqaror va jadal sur'atlar bilan rivojlantirish bo'yicha amalga oshirilayotgan islohotlar samarasini yaxshilash sohasidagi ilmiy-tadqiqot ishlariga alohida e'tibor qaratilgan. Zero iqtisodiyotning, ijtimoiy sohalarni qamrab olgan modernizatsiya jarayonlari, hayotning barcha sohalarini liberallashtirishni talab qilmoqda.

Ushbu ilmiy ma'ruza tezislari to'plamida mamlakatimiz va xorijlik turli yo'nalishlarda faoliyat olib borayotgan mutaxassislar, olimlar, professor-o'qituvchilar, ilmiy tadqiqot institutlari va markazlarining ilmiy xodimlari, tadqiqotchilari, magistr va talabalarining ilmiy-tadqiqot ishlari natijalari mujassamlashgan.

Mas'ul muharrirlar: DSc.prof. Turakulov O.X., t.f.n., dots. Baboyev A.M.

Tahrir hay'ati a'zolari: p.f.d.(DSc), prof. Turakulov O.X., t.f.n., dots. Baboyev A.M., t.f.f.d.(PhD), prof. Abduraxmanov R.A., p.f.f.d.(PhD) Eshankulov B.S., p.f.n., dots. Aliqulov S.T., p.f.n., dots. Alimov N.N., p.f.f.d.(PhD), dots. Alibayev S.X., t.f.f.d.(PhD), dots. Abdumalikov A.A., p.f.f.d.(PhD) Hafizov E.A., f.f.f.d.(PhD) dots., Norbekova B.Sh. p.f.f.d.(PhD) dots. Sindorov L.K., t.f.f.d.(PhD), dots. Nasirov B.U., b.f.f.d. (PhD) O'ralov A.I., p.f.n., dots. Aliqulov S.T., t.f.f.d.(PhD) Kuvandikov J.T., i.f.n., dots. Tsoy M.P., Sharipova S.F., Jo'rayev M.M.

Mazkur to'plamga kiritilgan ma'ruza tezislarining mazmuni, undagi statistik ma'lumotlar va me'yoriy hujjatlarning to'g'riligi hamda tanqidiy fikr-mulohazalar, keltirilgan takliflarga mualliflarning o'zlari mas'uldirlar.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ АДАПТИВНЫХ МЕТОДОВ РАСПОЗНАВАНИЯ ОБРАЗОВ С СОВРЕМЕННЫМИ МЕТОДАМИ МАШИННОГО ГЛУБОКОГО ОБУЧЕНИЯ

*Abdumanap Abdukarimov- texnika fanlari nomzodi, Mirzo Ulug'bek
nomidagi O'z MUJF "Axborot tizimlari va texnologiyasi" kafedrası katta
o'qituvchisi*

Аннотация. В работе рассматривается эволюция методов распознавания образов от классических алгоритмических подходов конца XX века до современных методов машинного и глубокого обучения. Особое внимание, уделяется «Адаптивным алгоритмам вычисления оценок в задачах распознавания образов: на примере медицинской диагностики». Проводится сопоставление идеи адаптивного вычисления оценок с современными направлениями: машинным обучением, обучением представлений, transfer learning, self-supervised learning, глубокими нейронными сетями, Transformer-архитектурами, domain adaptation и непрерывным обучением.

Показано, что непосредственная математическая преемственность между классическими алгоритмами и современными нейронными архитектурами отсутствует, однако существует важная концептуальная общность: стремление сделать процедуру распознавания не полностью фиксированной, а способной учитывать свойства поступающих данных. Для медицинской диагностики эта идея приобретает особое значение в связи с необходимостью адаптации моделей к различным типам данных, медицинским учреждениям, диагностическому оборудованию и изменениям распределения признаков.

Ключевые слова: распознавание образов, адаптивные алгоритмы вычисления оценок, классификация, медицинская диагностика, машинное обучение, глубокое обучение, CNN, Transformer, transfer learning, self-supervised learning, domain adaptation.

Распознавание образов является одним из фундаментальных направлений искусственного интеллекта, математической кибернетики и интеллектуального анализа данных. Его основная задача состоит в построении алгоритмов, позволяющих по совокупности наблюдаемых признаков определить принадлежность объекта к определённому классу.

В классической постановке имеется множество объектов, описанных системой признаков:

$[X=\{x_1, x_2, \dots, x_n\}]$, где каждому объекту соответствует вектор признаков

$[x=(x_1, x_2, \dots, x_m).]$

Необходимо определить отображение

$[F \rightarrow C,]$

где $(C=\{C_1, C_2, \dots, C_k\})$ — множество классов.

Для медицинской диагностики такими классами могут выступать различные состояния пациента, а признаками — результаты лабораторных

исследований, клинические показатели, изображения, сигналы и другие характеристики.

Одним из исторически интересных направлений развития данной области являются методы, основанные на вычислении оценок и адаптивном изменении процедуры распознавания. Интерес к этим работам сегодня обусловлен тем, что термин «адаптивность» вновь занимает центральное место в современных системах искусственного интеллекта.

В классическом алгоритме структура процедуры распознавания часто задаётся заранее. Выбираются признаки, задаётся мера сходства или правило классификации, после чего алгоритм применяется к новым объектам.

Адаптивный подход предполагает, что некоторые характеристики процедуры могут определяться или уточняться в процессе работы с данными[1-2].

В общем виде это можно представить следующим образом:

$[A(x, \theta) \rightarrow C,]$

где (x) — распознаваемый объект, (C) — решение, а (θ) — параметры алгоритма.

В неадаптивной системе:

$[\theta = \text{const.}]$ В адаптивной системе:

$[\theta = \theta(D),]$ где (D) — информация, полученная из обучающей или текущей выборки.

Таким образом, центральный принцип адаптивного распознавания состоит в том, что параметры процедуры распознавания должны определяться не только заранее заданной моделью, но и структурой доступной информации.

За прошедшие десятилетия вычислительные возможности резко возросли, а характер исходных данных изменился. Если ранние системы преимущественно работали с относительно небольшими таблицами признаков, то современные системы анализируют изображения высокого разрешения, медицинские томографические данные, видеопотоки, геномные данные и мультимодальную информацию.

Современная система может иметь дело одновременно с:

- большим количеством признаков;
- неполными данными;
- различным качеством измерений;
- дисбалансом классов;
- малым количеством размеченных объектов;
- изменением распределения данных;
- различиями между медицинскими учреждениями;
- различными диагностическими аппаратами.

Следовательно, проблема адаптации не исчезла. Напротив, она стала значительно сложнее.

Современная литература по медицинскому ИИ прямо использует понятия *adaptive* и *continuously learning algorithms*. Такие системы могут

обновляться на основе новых данных, получаемых в процессе эксплуатации, хотя подобная адаптация требует контроля безопасности и эффективности.

Таким образом, между ранними исследованиями адаптивного распознавания и современным искусственным интеллектом существует **концептуальная связь**, хотя математические средства реализации существенно различаются.

Исторически метод вычисления оценок разработанной академиком Ю.И. Журавлевым [3] и развитой в последующие годы его учениками принадлежал к классу алгоритмических подходов, в которых решение строится на основе определённой системы признаков, эталонов, мер близости и правил формирования итоговой оценки.

Современное машинное обучение решает аналогичную общую задачу уже другим способом.

Пусть имеется обучающая выборка

$[D = \{(x_i, y_i)\}_{i=1}^N]$, где (x_i) — объект, а (y_i) — известный класс.

Алгоритм обучения строит функцию:

$f_{\theta}(x) \rightarrow y$.

Параметры (θ) находятся в процессе обучения:

$\theta^* = \arg \min_{\theta} L(f_{\theta}(x), y)$,

где (L) — функция потерь.

Таким образом, современное машинное обучение перенесло адаптивность с уровня отдельных правил вычисления оценок на уровень автоматической оптимизации параметров модели.

Это принципиальное изменение. В классической системе специалист во многом определяет структуру алгоритма. В машинном обучении значительная часть структуры решения извлекается из данных.

Одним из главных этапов развития распознавания образов стал переход от ручного конструирования признаков к автоматическому формированию представлений.

В классической системе:

$\{\text{объект}\} \rightarrow \{\text{признаки}\} \rightarrow \{\text{классификатор}\}$.

]

В современных глубоких сетях:

$\{\text{объект}\} \rightarrow \{\text{обучаемое представление}\} \rightarrow \{\text{классификация}\}$.

Это особенно существенно для изображений.

Нейронная сеть может последовательно формировать представления различной сложности:

$X \rightarrow Z_1 \rightarrow Z_2 \rightarrow \dots \rightarrow Z_L \rightarrow Y$.

На ранних уровнях могут формироваться простые признаки, на последующих — более сложные комбинации признаков.

Современные обзоры медицинского анализа изображений показывают широкое применение глубокого обучения для классификации, сегментации, обнаружения патологий и других задач.

В этом отношении произошёл важный переход: **ранние методы:** специалист определяет существенные признаки; **современные методы:** система сама обучает представление, наиболее полезное для поставленной задачи.

Существенный этап развития распознавания изображений связан со сверточными нейронными сетями (CNN). Их принципиальная особенность заключается в автоматическом извлечении пространственных признаков изображения.

Упрощённо операцию свёртки можно представить:

$[Y(i,j) = \sum_m \sum_n X(i+m,j+n)K(m,n),]$ где (X) — входное изображение, (K) — обучаемое ядро, а (Y) — карта признаков.

В медицинской диагностике CNN используются для анализа рентгеновских изображений, КТ, МРТ, ультразвуковых изображений и других медицинских данных.

Однако у CNN существует принципиальное отличие от классических методов вычисления оценок: параметры фильтров не задаются полностью специалистом, а обучаются на данных.

Именно здесь появляется новая форма адаптации:

$[K=K(D).]$

То есть параметры представления формируются непосредственно в процессе обучения.

Особенно важным направлением стало transfer learning — перенос знаний предварительно обученной модели на новую задачу.

Общая схема:

$[D_{\text{source}} \rightarrow M_{\text{pretrained}}]$ затем $[M_{\text{pretrained}} + D_{\text{target}} \rightarrow M_{\text{adapted}}].$

Это особенно актуально для медицинской диагностики, поскольку получение больших размеченных медицинских наборов данных является сложной задачей.

Вместо обучения модели с нуля используется уже сформированное представление, которое затем адаптируется к конкретной диагностической задаче.

Таким образом, можно провести концептуальную параллель:

адаптивный алгоритм вычисления оценок

→ адаптация процедуры распознавания к данным

transfer learning

→ адаптация предварительно обученной модели к новой предметной области.

Одной из наиболее важных современных проблем медицинского ИИ является недостаток размеченных данных. Разметка медицинских изображений требует участия специалистов и является трудоёмким

процессом. Обзор 2024 года по self-supervised learning [4]отмечает, что объём медицинских изображений растёт быстрее, чем возможности их ручной разметки.

Self-supervised learning позволяет сначала использовать большое количество неразмеченных данных для обучения представления, а затем выполнять дообучение на относительно небольшом количестве размеченных примеров.

Схема имеет вид:

$[D_{\text{unlabeled}} \rightarrow Z][Z + D_{\text{labeled}} \rightarrow \text{Classifier}.]$

Для медицинского распознавания это открывает возможность строить системы при существенно меньшем объёме ручной разметки.

Исследования также показывают, что self-supervised pretraining может улучшать последующее обучение диагностических моделей, особенно когда неразмеченных данных значительно больше, чем размеченных.

В заключении приведем таблицу сравнительного анализа периода 1990- 2026 гг

Характеристика	Подход адаптивных алгоритмов вычисления оценок	Современные методы
Основной объект	Объекты, описанные признаками	Изображения, сигналы, текст, мультимодальные данные
Основная идея	Адаптивное вычисление оценок	Адаптация параметров и представлений
Признаки	В значительной степени задаются заранее	Могут автоматически обучаться
Обучение	Алгоритмическое, на основе выборки	Оптимизация параметров модели
Классификация	Вычисление оценок и принятие решения	Нейронные классификаторы, ансамбли, Transformer
Адаптация	Изменение процедуры/оценок	Fine-tuning, domain adaptation, continual learning
Данные	Относительно небольшие выборки	Большие и высокоразмерные наборы
Медицинское применение	Медицинская диагностика	Радиология, патология, кардиология, геномика и др.
Объяснимость	Алгоритмическая интерпретируемость	XAI, attention, saliency maps

Вычислительные ресурсы	ЭВМ того периода	GPU/TPU и распределённые вычисления
Мультимодальность	Ограниченная	Один из активно развиваемых подходов
Работа с неразмеченными данными	Ограниченная	Self-supervised learning
Перенос знаний	Не являлся центральным современным термином	Transfer learning
Изменение домена	Адаптация алгоритма	Domain adaptation

Работы посвящённые адаптивным алгоритмам вычисления оценок в задачах распознавания образов на примере медицинской диагностики, относятся к важному этапу развития отечественной школы распознавания образов.

Современный этап характеризуется развитием:

- глубоких нейронных сетей;
- CNN;
- Transformer и Vision Transformer;
- transfer learning;
- self-supervised learning;
- domain adaptation;
- continual learning;
- multimodal learning;
- explainable AI.

При этом фундаментальная задача остаётся прежней — по совокупности наблюдаемых данных получить обоснованное решение о принадлежности объекта к определённому классу.

Наиболее существенное изменение заключается в том, что современные системы способны самостоятельно формировать признаки, оптимизировать параметры модели, переносить знания между задачами и адаптироваться к новым данным.

Поэтому научное значение ранних исследований адаптивного распознавания сегодня может быть переосмыслено следующим образом:

от адаптивного вычисления оценок — к адаптивному обучению модели.

Именно эта линия развития представляет особый интерес для дальнейших исследований в области интеллектуальных систем медицинской диагностики.

Литература и источники

1. Адылова Ф. Т. Адаптивный выбор опорных множеств в методе вычисления оценок. Докл. Академии наук Узбекистана, №3
2. Абдукаримов А. *Адаптивные алгоритмы вычисления оценок в задачах распознавания образов. МОНОГРАФИЯ, стр 78, Джизак 2023.*

3. Абдукаримов А. Адаптивные алгоритмы вычисления оценок в задачах распознавания образов: на примере медицинской диагностики: автореферат диссертации на соискание учёной степени кандидата технических наук. Ташкент, 1991. 20 с. Российская государственная библиотека.

4. Zeng X., Abdullah N., Sumari P. *Self-supervised learning framework application for medical image analysis: a review and summary*. BioMedical Engineering OnLine, 2024.

5. *A survey of the impact of self-supervised pretraining for diagnostic tasks in medical X-ray, CT, MRI, and ultrasound*. BMC Medical Imaging, 2024.

6. *A review of deep learning and Generative Adversarial Networks applications in medical image analysis*. Multimedia Systems, 2024.

7. *Deep learning for medical image segmentation: State-of-the-art advancements and challenges*. Informatics in Medicine Unlocked, 2024.

8. Chen X. et al. *Dual Adaptive Disentangled Representation Learning With Multimodal Data for Disease Diagnosis*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2026.

9. *Artificial Intelligence and Machine Learning in Diagnostic Radiology: A Paradigm Shift Toward Predictive Neuroimaging and Early Detection of Brain Disorders*, 2026.

SARALASH TEXNOLOGIK JARAYONI AVTOMATIK BOSHQARILADIGAN KOMBINATSIYALASHGAN ELEKTR QURILMA

T.f.n., katta ilmiy xodim Rosaboyev Abdukodir Tuxtakuziyevich

Qishloq xo'jaligini mexanizatsiyalash ilmiy-tadqiqot instituti,

rosaboev1961@mail.ru

Jamolova Fotima Rustam qizi Toshkent kimyo texnologiya instituti

Yangier filiali, jamolova fotima 9292@gmail.com

Annotatsiya: Maqolada mayda urug'larni saralash uchun taklif qilinayotgan kombinatsiyalashgan qurilmaning tuzilishi va ishlash prinsipi to'g'risida ma'lumotlar keltirilgan.

Kalit so'zlar: saralash, texnologik jarayon, avtomatik boshqariladigan, kombinatsiyalashgan elektr qurilma, elektr maydon kuchi, urug'lik fraksiya, texnik fraksiya.

Ma'lumki, qishloq xo'jalik ekinlari, jumladan, mayda urug'li ekinlardan mo'l hosil yetishtirishda, boshqa agrotexnik tadbirlar bilan bir qatorda, ekishga tayyorlanadigan urug'larning sifat ko'rsatkichlari ham muhim rol o'ynaydi. Bunga sabab, sifatli, biologik xossalari bir-biriga yaqin, laboratoriya va dala sharoitidagi unuvchanligi hamda potensial hosildorligi yuqori bo'lgan urug'lar mo'l hosil garovi hisoblanadi. Lekin hozirgi kungacha respublika qishloq xo'jaligida mayda urug'larni saralash uchun biron-bir ilmiy asoslangan qurilma mavjud emas. Shuning uchun dehqonlar mayda urug'larni saralamasdan ekishga majbur bo'lishayapti. Natijada, bir gektar yerga urug'lik sarfi 1,3-1,5 marta ko'l sarflanib, niholarni ola