

**Машинно обучение за цитологичен анализ като STEAM метод
в обучението по компютърни науки**
Ивайло Граматиков

**Machine learning for cytological analysis as a STEAM method
in computer science education**
Ivaylo Gramatikov

Abstract:

This paper presents a didactic scenario in computer science education in which tenth-grade students design a machine learning model for recognizing morphological changes in plant cells caused by nitrate stress. The three-phase workflow covers microscopic observation and manual annotation, training with Cellpose 4.0 and ResNet18 (PyTorch), and integration into a React/Vite web application with FastAPI. Observations indicate that active participation in building a model from scratch develops deeper understanding of ML system limitations than using ready-made solutions. Specific student difficulties and the pedagogical value of model errors as learning moments are discussed.

Keywords: machine learning, STEAM education, cell segmentation, nitrate stress, interdisciplinary learning, computer vision

For contacts: Ivaylo Gramatikov, Trakia University, Stara Zagora, gramatikov88@gmail.com

ВЪВЕДЕНИЕ

Интеграцията на машинно обучение в образованието е сред водещите тенденции в STEAM педагогиката. ЮНЕСКО препоръчва STEAM в съчетание с проектно базирано обучение като ефективна стратегия за развиване на AI грамотност [1]. Същевременно едва около 15% от изследванията върху AI в образованието включват истинска междупредметна интеграция [2]. Това поражда въпроса как обучението по компютърни науки може да излезе от абстрактните упражнения и да предложи задача, която изисква едновременно технически умения и разбиране на предметната област.

Настоящият доклад представя дидактически сценарий, реализиран с ученици от десети клас. Задачата е проектирането на модел за машинно обучение, разпознаващ морфологични промени в растителни клетки при нитратен стрес. Изборът на биологичен контекст не е случаен — нитратите участват в множество сигнални и метаболитни процеси и предизвикват видими структурни изменения, наблюдаеми под оптичен микроскоп [3]. Тази наблюдаемост прави задачата подходяща за ученически проект: данните идват от реални биологични проби, заснети и анотирани от самите ученици.

Работният процес обхваща три фази: микроскопско наблюдение с ръчно анотиране на клетъчни изображения; обучение на класификационен модел чрез Cellpose 4.0 за сегментиране и ResNet18 (PyTorch) за класификация; интеграция в уеб приложение с React/Vite и FastAPI. Целта на изследването е да се проследи доколко ученици могат да изградят работещ ML работен процес (pipeline) от суровите данни до крайния продукт, както и да се изследва педагогическата стойност на грешките на модела като учебен момент. Основната хипотеза е, че активното участие в изграждането на модел от нулата развива по-задълбочено

разбиране за ограниченията на ML системите в сравнение с използването на готови решения.

ИЗЛОЖЕНИЕ

Теоретична рамка

Подходът STEAM разширява STEM рамката с изкуствата и хуманитарните дисциплини, насърчавайки творческо мислене и визуализация на комплексни проблеми. В компютърните науки STEAM се реализира, когато техническата задача е вградена в реален проблем от друга предметна област [4]. Настоящият сценарий следва тази логика: биологичният контекст не е декорация, а условие за качеството на резултата.

Технологичният избор е педагогически обоснован. Cellpose е универсален алгоритъм за клетъчно сегментиране върху разнообразни микроскопски изображения без допълнително обучение [5], с GUI за визуална верификация и ръчна корекция. ResNet18 е избран заради баланса между сложност и достъпност: чрез трансферно обучение върху ImageNet тегла моделът може да бъде ефективно дообучен дори с малки набори от данни [6]. Комбинацията от двата модела позволява на учениците да разберат разликата между сегментиране (къде е обектът) и класификация (какъв е той).

Биологичната основа почива на установения факт, че нитратите действат като сигнална молекула, модулираща генната експресия и клетъчната морфология [3]. Излишъкът на нитрати води до промени в размера на клетките и вакуолната структура, достъпни за наблюдение дори с училищен оптичен микроскоп.

Методология и дизайн на сценария

Сценарият е реализиран в рамките на месец и половина с 7 ученици от десети клас, разпределени в два екипа. Всеки екип поема отговорност за определен етап от работния процес, но всички участници преминават през трите фази. Работата е организирана в локална развойна среда.

Фаза 1: Микроскопско наблюдение и аотиране

Учениците работят с биологични проби от растителна тъкан, подложена на различни концентрации нитратен разтвор. Пробите се наблюдават чрез оптичен микроскоп с камера за дигитално заснемане. След кратко въведение в клетъчната морфология, учениците самостоятелно заснемат изображения и ги организират в структурирана файлова система с метаданни за концентрацията и експозицията.

Аотирането се извършва чрез Cellpose GUI с ръчно очертаване на клетъчни граници. Учениците дефинират категории морфологични изменения: нормална клетка, клетка с увеличена вакуола, клетка с деформирана клетъчна стена, клетка с плазмолиза. Процесът на аотиране е педагогически значим сам по себе си, защото принуждава учениците да взимат решения и да осъзнаят субективността, присъща на ръчното етикетироване.

Фаза 2: Обучение на модела

Пайплайнът е разделен на сегментиране (Cellpose 4.0) и класификация (ResNet18, PyTorch). Учениците сравняват автоматично генерираните маски с ръчните си аотации и коригират грешките, създавайки обучителен набор с високо качество. Този итеративен процес е ключов, защото учениците виждат на практика какво означава понятието ground truth (референтна истина).

ResNet18 е инициализиран с предварително обучени ImageNet тегла, а последният слой е заменен с нов, съответстващ на дефинираните класове. Обучението се изпълнява локално в училищната лаборатория. Учениците експериментират с хиперпараметри (learning rate, брой епохи, batch size (размер на партидата)) и наблюдават ефекта върху кривите на загуба и точност.

Фаза 3: Интеграция в уеб приложение

Обученият модел се интегрира в уеб приложение. Бекендът (FastAPI) приема изображение, изпълнява сегментиране и класификация, и връща резултати в JSON формат. Фронтендът (React/Vite) визуализира очертаните клетки, цветово кодирани по категория, и обобщена статистика за процентното разпределение. Тази фаза е ценна, защото учениците за пръв път виждат своя модел извън средата на Jupyter Notebook и се сблъскват с реални софтуерно-инженерни предизвикателства.

Наблюдения и резултати

Във Фаза 1 най-значителното затруднение е биологичната неопределеност при аотирането. Различните екипи първоначално категоризират едни и същи клетки по различен начин (inter-annotator disagreement (несъгласуваност между аотаторите)). Тази ситуация се оказва полезна педагогически: учениците интуитивно разбират защо качеството на данните е от критично значение за ML, без да им е необходима теоретична лекция.

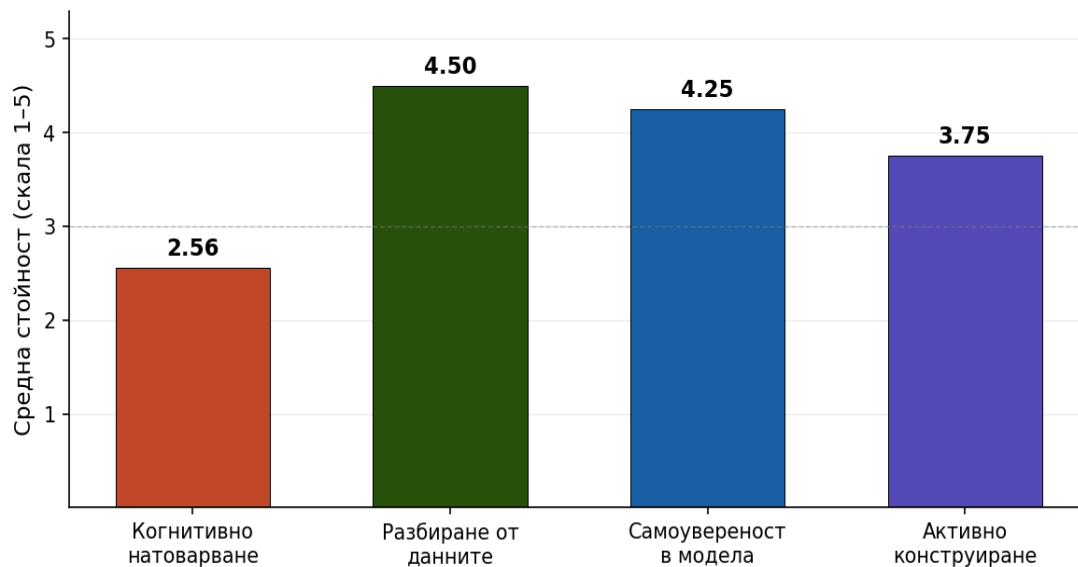
Във Фаза 2 основното предизвикателство е навигацията в нелинейната софтуерна среда — паралелна работа с файлова система, Cellpose GUI, Python скриптове, PyTorch и терминал. Учениците, свикнали с линейни учебни среди, първоначално изпитват дезориентация. Във Фаза 3 затрудненията са от софтуерно-инженерен характер (REST API, асинхронна комуникация), но се възприемат по-позитивно, защото резултатът е видим и демонстрируем.

Количествените метрики на модела (accuracy, precision, recall) ще бъдат публикувани след приключване на проекта. Качествените наблюдения показват, че моделът разпознава надеждно крайните случаи (ясно нормални клетки и клетки с тежка плазмолиза), но допуска грешки при междинните категории — очаквано поведение при малък обучителен набор и субективно аотиране.

Грешките на модела се превръщат в най-продуктивната точка на дискусия. Когато моделът класифицира погрешно клетка, учениците изследват причината: некачествено изображение, непоследователно аотиране, недостатъчни примери или архитектурно ограничение. Тази аналитична дейност изисква едновременно биологично и техническо познание — точно тук се реализира интердисциплинарният характер на задачата. Учениците, които активно участват в аотирането, демонстрират по-задълбочено разбиране за ограниченията на модела.

Резултати от ученическата анкета

В края на проекта е проведена анонимна анкета сред 7 участници, структурирана по 11 твърдения с Ликертова скала от 1 до 5. Въпросите са групирани в четири тематични оси: когнитивно натоварване при навигация в средата, разбиране, извлечено от работата с реални данни, самоувереност в управлението на модела и усещане за активно конструиране на решението. Обобщените резултати са визуализирани на вж. Фиг. 1



Фиг. 1. Средни стойности по тематични групи от анкетата (n = 7).

Най-ниска стойност получава групата „когнитивно натоварване“ (средно 2.56), което показва, че въпреки сложността на инструментариума учениците не се чувстват претоварени. По-конкретно, ориентирането в стъпките на изграждането на модела е оценено с 4.00, а усещането за „изгубване“ в средата — с 2.00. Единствено вземането на решения относно избор на библиотеки и функции получава умерена оценка (2.50), което съответства на първоначалния опит на учениците с PyTorch.

Най-висока оценка получават твърденията, свързани с разбирането, извлечено от данните (средна стойност 4.50). Анотирането на клетки, осъзнаването на многозначността в биологичната диагностика и интересът към грешките на модела получават идентични средни стойности — което потвърждава хипотезата, че активната работа с реални изображения формира по-задълбочено разбиране от четенето на теоретични дефиниции. Самоувереността в управлението на модела (средно 4.25) и усещането за активно конструиране (средно 3.75) са също положителни, макар че последното показва, че част от учениците все още възприемат работата повече като следване на насоки, отколкото като самостоятелно проектиране — аспект, който заслужава педагогическа корекция.

Дискусия

Сценарият потвърждава, че интердисциплинарният подход в обучението по компютърни науки е осъществим на ниво средно образование и генерира учебни резултати, трудно постижими в рамките на монодисциплинарен курс. Когато учениците работят с реални биологични данни, всяко техническо решение придобива конкретен смисъл, защото е обвързано с въпроса: „Ще разпознае ли моделът правилно увредената клетка?“ Това е в съответствие с тенденцията в AI образованието, която подчертава необходимостта учениците да разбират не само алгоритмите, но и контекста [1].

Сценарият демонстрира, че дори с малка група ученици и стандартно училищно оборудване е възможно изграждането на пълноценен ML работен процес с реално приложение. Координацията с преподавател по биология

обогатява учебния опит и създава модел за междупредметно сътрудничество, който може да бъде адаптиран към различни училищни контексти. Бъдещи изследвания биха могли да разширят обхвата на сценария чрез включване на повече участници и прилагане на предварителен и последващ тест за ML грамотност.

Перспективните посоки за развитие включват: замяна на биологичния контекст с друга предметна област (геология, екология, медицинска диагностика) при запазване на трифазната структура; интеграция на автоматизирано оценяване на съгласуваността между анотаторите; използване на по-нови версии на Cellpose с функции за възстановяване на изображения [7], което би разширило приложимостта към по-ниско качество, типично за училищни микроскопи.

ЗАКЛЮЧЕНИЕ

Настоящият доклад представи дидактически сценарий, в който ученици от десети клас изграждат ML модел за разпознаване на морфологични промени в растителни клетки под нитратен стрес. Трифазният дизайн позволява преминаване през пълния цикъл на един ML проект. Наблюденията потвърждават, че активното участие в изграждането на модел върху реални данни развива по-задълбочено и по-критично разбиране за ограниченията на ML системите. Грешките на модела се превръщат в най-ценния учебен момент, защото изискват едновременно биологично и техническо мислене. Интердисциплинарният подход събужда любопитство към общообразователните предмети и демонстрира как професионалните дисциплини намират реално приложение в решаването на конкретни проблеми.

ЛИТЕРАТУРА

1. UNESCO, AI Competency Framework for Students, 2024.
2. Zhai, X. et al., Artificial Intelligence in Elementary STEM Education: A Systematic Review, *arXiv:2511.00105*, 2025.
3. Landrein, B. et al., Nitrate modulates stem cell dynamics in Arabidopsis shoot meristems through cytokinins, *PNAS*, 115(6), 2018.
4. Segarra-Morales, P. et al., Which Maker and STEAM integration styles stand out in education?, *Int. J. of Technology and Design Education*, Springer, 2025.
5. Stringer, C., Pachitariu, M., Cellpose: a generalist algorithm for cellular segmentation, *Nature Methods*, 18(1), 100-106, 2021.
6. He, K. et al., Deep Residual Learning for Image Recognition, *Proc. IEEE CVPR*, 770-778, 2016.
7. Stringer, C., Pachitariu, M., Cellpose3: one-click image restoration for improved cellular segmentation, *Nature Methods*, 22(3), 592-599, 2025.