



INTERNATIONAL SCIENCE REVIEWS



№2 (5) 2024

Natural Sciences and
Technologies series





INTERNATIONAL SCIENCE REVIEWS

Natural Sciences and Technologies series

Has been published since 2020

№2 (5) 2024

Astana

INTERNATIONAL SCIENCE REVIEWS. NATURAL SCIENCES AND TECHNOLOGIES SERIES ЖУРНАЛЫНЫҢ РЕДАКЦИЯСЫ

БАС РЕДАКТОР

Қалимолдаев Мақсат Нұрадилович, техникалық ғылымдар докторы, ҚР ҰҒА академигі, профессор, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институты бас директорының кеңесшісі, бас ғылыми қызметкері (Қазақстан)

БАС РЕДАКТОРДЫҢ ОРЫНБАСАРЫ

Мырзағалиева Анар Базаровна, биология ғылымдарының докторы, профессор, бірінші вице-президент, Астана халықаралық университеті (Қазақстан);

РЕДАКТОРЛАР:

- **Сейтқан Айнур Сейтқанқызы**, техника ғылымдарының кандидаты, PhD, жаратылыстану ғылымдары жоғары мектебінің деканы, Астана халықаралық университеті (Қазақстан);

- **Муканова Асель Сериковна**, PhD, Ақпараттық технологиялар және инженерия жоғары мектебінің деканы, Астана халықаралық университеті (Қазақстан);

- **Абдилдаева Асель Асылбековна**, PhD, қауымдастырылған профессор, Әл-Фараби атындағы ҚазҰУ (Қазақстан);

- **Хлахула Иржи** PhD, профессор, Познаньдағы Адам Мицкевич атындағы университет (Польша);

- **Редферн Саймон А.Т.**, PhD, профессор, Наньян технологиялық университеті (Сингапур);

- **Сяолей Фенг**, PhD, Наньян технологиялық университеті (Сингапур);

- **Шуджаул Мулк Хан**, PhD, профессор, Каид-және-Азам университеті (Пакистан);

- **Базарнова Наталья Григорьевна**, химия ғылымдарының докторы, профессор, Химия және химиялық-фармацевтикалық технологиялар институты (Ресей);

- **Черёмушкина Вера Алексеевна**, биология ғылымдарының докторы, профессор, РҒА СБ Орталық Сібір ботаникалық бағы (Ресей);

- **Тасболатұлы Нұрболат**, PhD, Ақпараттық технологиялар және инженерия жоғары мектебі деканының орынбасары, Астана халықаралық университеті (Қазақстан);

- **Байшоланов Сакен Советович**, география ғылымдарының кандидаты, доцент, Астана халықаралық университеті (Қазақстан);

- **Нуркенов Серик Амангельдинович**, PhD, қауымдастырылған профессор, Астана халықаралық университеті (Қазақстан).

**РЕДАКЦИЯ ЖУРНАЛА INTERNATIONAL SCIENCE REVIEWS.
NATURAL SCIENCES AND TECHNOLOGIES SERIES**

ГЛАВНЫЙ РЕДАКТОР

Калимолдаев Максат Нурадилович, доктор технических наук, академик НАН РК, профессор, ГНС, советник генерального директора Института информационных и вычислительных технологии КН МНВО РК (*Казахстан*)

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

Мырзагалиева Анар Базаровна, доктор биологических наук, профессор, первый вице-президент, Международный университет Астана (*Казахстан*)

РЕДАКТОРЫ:

- **Сейткан Айнур Сейтканкызы**, кандидат технических наук, PhD, декан высшей школы естественных наук, Международный университет Астана (*Казахстан*);

- **Муканова Асель Сериковна**, PhD, декан Высшей школы информационных технологии и инженерии, Международный университет Астана (*Казахстан*);

- **Абдилдаева Асель Асылбековна**, PhD, ассоциированный профессор, Казахский национальный университет имени Аль-Фараби (*Казахстан*);

- **Хлахула Иржи** PhD, профессор, Университет имени Адама Мицкевича в Познани (*Польша*);

- **Редферн Саймон А.Т.**, PhD, профессор, Наньянский технологический университет (*Сингапур*);

- **Фенг Сяoley**, PhD, Наньянский технологический университет (*Сингапур*);

- **Шуджаул Мулк Хан**, PhD, профессор, Университет Каид-и Азама (*Пакистан*);

- **Базарнова Наталья Григорьевна**, доктор химических наук, профессор, Институт химии и химико-фармацевтических технологий (*Россия*);

- **Черёмушкина Вера Алексеевна**, доктор биологических наук, профессор, Центральный Сибирский Ботанический сад СО РАН (*Россия*);

- **Тасболатұлы Нұрболат**, PhD, заместитель декана Высшей школы информационных технологии и инженерии, Международный университет Астана (*Казахстан*);

- **Байшоланов Сакен Советович**, кандидат географических наук, доцент, Международный университет Астана (*Казахстан*);

- **Нуркенов Серик Амангельдинович**, PhD, ассоциированный профессор, Международный университет Астана (*Казахстан*);

**EDITORIAL TEAM OF THE JOURNAL INTERNATIONAL SCIENCE REVIEWS.
NATURAL SCIENCES AND TECHNOLOGIES SERIES**

CHIEF EDITOR

Maksat Kalimoldayev, Doctor of Technical Sciences, Academician of NAS RK, Professor, SRF, CEO's councilor «The Institute of Information and Computational Technologies» CS MSHE RK (Kazakhstan)

DEPUTY CHIEF EDITOR

Anar Myrzagaliyeva, Doctor of Biological Sciences, Professor, First Vice-President, Astana International University (Kazakhstan)

EDITORS:

- **Ainur Seitkan**, Candidate of Technical Sciences, PhD, Dean of the Higher School of Natural Sciences, Astana International University (Kazakhstan);
- **Assel Mukanova**, PhD, Dean of the Higher School of Information Technology and Engineering, Astana International University (Kazakhstan);
- **Assel Abdildayeva**, PhD, Associate Professor, of the Department of Artificial Intelligence and Big Data, Al-Farabi Kazakh National University (Kazakhstan);
- **Jiri Chlachula**, PhD, Dr.Hab., Full Professor, Adam Mickiewicz University, Poznań (Poland);
- **Simon A.T. Redfern**, PhD, Professor, Nanyang Technological University (Singapore);
- **Xiaolei Feng**, PhD, Nanyang Technological University (Singapore);
- **Khan Shujaul Mulk**, PhD, Professor, Quaid-i-Azam University (Pakistan);
- **Natal'ya Bazarnova**, Doctor of Chemical Sciences, Professor, Institute of Chemistry and Chemical-Pharmaceutical Technologies (Russia);
- **Vera Cheryomushkina**, Doctor of Biological Sciences, Professor, Central Siberian Botanical Garden SB RAS (Russia);
- **Nurbolat Tasbolatuly**, PhD, Deputy Dean of the Higher School of Information Technology and Engineering, Astana International University (Kazakhstan);
- **Saken Baisholanov**, Candidate of Geographical Sciences, Associate Professor, Astana International University (Kazakhstan);
- **Serik Nurkenov**, PhD, Associate Professor, Astana International University (Kazakhstan).

Editorial address: 8, Kabanbay Batyr avenue, of.316, Nur-Sultan,

Kazakhstan, 010000

Tel.: (7172) 24-18-52 (ext. 316)

E-mail: natural-sciences@aiu.kz

International Science Reviews NST - 76153

International Science Reviews

Natural Sciences and Technologies series

Owner: Astana International University

Periodicity: quarterly

Circulation: 500 copies

CONTENT

1. С.А.Жанабаева ТРЕБОВАНИЯ К СОВРЕМЕННОМУ УРОКУ ГЕОГРАФИИ.....	7
2. А.Ж.Жанибеков, Е.Н Сагатбаев ГЕОГРАФИЯНЫ ОҚЫТУДАҒЫ ОЙЫН ТЕХНОЛОГИЯЛАР: ТҮРЛІЛІГІ, ИНТЕРАКТИВТІЛІКІ ЖӘНЕ БІЛІМ БЕРУДЕГІ ПАЙДАСЫ.....	12
3. Ж.А. Адамжанова, Н. С, Ауезова, Д.Е.Төлепберген СТЕВИЯ ӨСІМДІГІНІҢ БИОЛОГИЯЛЫҚ ЕРЕКШЕЛІКТЕРІ ЖӘНЕ КАЛУСТАН ӨСІРУ ЖОЛДАРЫ	23
4. Б.Н. Бекмаханбет, Д.А. Нургалиева ИСПОЛЬЗОВАНИЕ ТЕСТОВ И ТЕСТОВЫХ ЗАДАНИЙ В ПРОЦЕССЕ УПРАВЛЕНИЯ КАЧЕСТВОМ УРОКОВ ПО ХИМИИ	30
5. Ш.Қ.Кәрім, А.С.Сейтқан ОПРЕДЕЛЕНИЕ УРОВНЯ ШУМА В УЧЕБНЫХ АУДИТОРИЯХ МЕЖДУНАРОДНОГО УНИВЕРСИТЕТА АСТАНА	37
6. Н. Досанов, А.Ерланұлы, Е.Алданов БАЙЕСОВСКАЯ ПАРАДИГМА В НЕЙРОННЫХ СЕТЯХ	46
7. А.Д.Тишбаева, Л.Т.Кусепова, Е.К.Қайұпов, М.Ж.Қалдарова, А.Е.Назырова LXD ЖӘНЕ ОНЫ ОПЕРАЦИЯЛЫҚ ЖҮЙЕНІ ВИРТУАЛДАНДЫРУДА ҚОЛДАНУ ЕРЕКШЕЛІКТЕРІ	54
8. Ж.Т.Абдуллаева, Д.Е.Жеңіс МАППИНГ БОЛЬШИХ ДАННЫХ: СОВРЕМЕННЫЕ ПОДХОДЫ И МЕТОДЫ В 2024 ГОДУ	63
9. Ж.Б.Семейхан, М.Ж.Қалдарова, А.Е.Назырова, Л.Т.Кусепова МЕХАНИЗМ ОБЪЕДИНЕНИЯ ДАННЫХ ПРИ МЕТОДЕ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ.....	67
10. Shalbai T., Kaldarova M., Nazyrova A., Sultangaziyeva A., Kussepova L. RECONSTRUCTION OF GEOMETRIC MODELS OF OBJECTS FROM SATELLITE IMAGES BASED ON ARTIFICIAL NEURAL NETWORKS	77
11. Е.А. Жумағалиев, Л.Т.Кусепова, Е.К.Қайұпов, А.Е.Назырова, М.Ж.Қалдарова DOCKER ЗАМАНАУИ ҚОЛДАНБАЛАРДЫ ӨЗІРЛЕУ ЖӘНЕ ОРНАЛАСТЫРУ ТӘСІЛДЕРІ	87

ТРЕБОВАНИЯ К СОВРЕМЕННОМУ УРОКУ ГЕОГРАФИИ

С.А.Жанабаева

Международный университет Астана

Ст.преподаватель ВШЕН

Аннотация: В эпоху массовой глобализации предъявляются новые требования к современному образованию, связанные с умением обучающихся ориентироваться в потоке информации; творчески решать возникающие проблемы; применять на практике полученные знания, умения и навыки. В данной статье отмечены существенные различия традиционного и современного урока географии, какие показатели характеризуют современный урок.

Ключевые слова: педагогика, география, методика преподавания географии.

География - предмет, при освоении которого ведущей является познавательная деятельность, где основные виды учебных действий обучающихся – умение составлять характеристику, объяснять, сравнивать, систематизировать, выявлять зависимость и анализировать. Приписываемая географии учебная «легкость» на самом деле всегда была обманчивой, будучи одной из древнейших наук, география уверенно сохраняет свой глубокий познавательный потенциал. По этой причине географию невозможно вычеркнуть из интеллектуального процесса и она не требует к себе снисхождения.

Современный урок географии - неотъемлемая часть всей жизнедеятельности обучающихся, так как именно на уроке студент больше всего познает, на уроке происходит его воспитание, развитие, раскрывается его индивидуальность, складываются интересы, формируется личность [1].

Каковы же различия традиционного и современного урока? Первым показателем различий служат цели урока, с осознания и формулировки которых начинается подготовка педагога к любому уроку. В современной дидактике выделяют четыре группы задач: задачи усвоения знаний; формирование умений; воспитания творческих способностей; задачи, связанные с достижением эмоционального отношения к тем ценностям, которые воплощены в изучаемом материале [4]. Цели традиционного урока связаны с усвоением знаний и умений, воспитание при этом осуществляется по ходу обучения. Цель современного урока – формирование и развитие

личности студента в опоре на использование всех компонентов образования. Цели современного урока направлены на развитие мотивов учения, мышления и способностей, на развитие восприятия, внимания, памяти, речи, воображения обучающихся.

Второй показатель различий традиционного и современного урока заключается в изменении роли и функции преподавателя на занятии. На традиционном уроке основная функция преподавателя – передача учебной информации и создание условий для ее усвоения. На современном уроке преподаватель выступает организатором учебной деятельности обучающихся, ставит цель, обозначает пути ее достижения, способы учебной работы, дает задания, консультирует. Главное на таком уроке – самостоятельная деятельность, решение учебных задач, учебных проблем, построенных на содержании учебного материала [1].

Наиболее существенный признак современного урока – изменения отношений между педагогом и обучающимся. На традиционном уроке преобладает авторитарный стиль общения. Современный урок характеризуется сотрудничеством преподавателя и студента в выборе различных форм проведения урока, теоретических и практических видов деятельности, оценке результатов учебного труда.

Современный урок при творческом подходе к его построению не может быть стандартным, всегда одинаковым по структуре. Ведь у традиционного урока наблюдается четкое распределение времени и последовательность таких структурных элементов, как проверка знаний и умений, изучение нового материала, закрепление, постановка домашнего задания. У современного урока иная логика построения процесса обучения и иное распределение времени. На современном уроке происходит слияние его отдельных этапов. Главное на уроке – применение знаний и умений в процессе решения учебных задач, построенных на новом материале.

На традиционном уроке почти отсутствует общение обучающихся в процессе учебной работы. Современный урок направлен на формирование личности студента в условиях коллективной учебной деятельности с учетом индивидуальных особенностей обучающихся. Только в коллективе при тесном сотрудничестве ребят с преподавателем и между собой развиваются такие важные качества личности, как командный дух и трудолюбие.

Показателем качества урока уже не могут быть только эрудиция и методическое мастерство педагога. Главный его показатель – организация деятельности обучающихся, что должно способствовать подготовке их к жизни, к поведению в природе, в обществе и на производстве [2].

В эпоху массовой глобализации предъявляются новые требования к современному образованию, связанные с умением обучающихся

ориентироваться в потоке информации; творчески решать возникающие проблемы; применять на практике полученные знания, умения и навыки. Поэтому задача преподавателя – научить творчески мыслить ребят, то есть вооружить таким важным умением как уметь учиться. Здесь следует учесть что, одним из направлений модернизации системы географического образования является внедрение IT технологий и мультимедиа [4].

Современная молодежь, в большинстве своем свободно вращающаяся в компьютерном мире, сама ищет возможности использования компьютера при выполнении заданий, особенно если эти задания связаны с привлечением большого массива современной информации, или со сложными графическими построениями, или с высокими требованиями к оформлению работы. В таких условиях преподаватель просто обязан приложить усилия к скорейшему освоению и использованию всех полезных новшеств, которые предлагает технический прогресс в преподавании географии. Это уже продиктовано самой жизнью.

В географии заложены огромные возможности для применения новых технологий. Большой интерес представляет использование обучающих программ, мультимедиа, создание учебных программ и учебных пособий, использование Интернета.

Не менее важным этапом современного урока является мотивационный блок. Психологи определяют мотивацию как «совокупность всех факторов (как личностных, так и ситуативных), которые побуждают человека к активности». Для этого существуют разнообразные приёмы: рассмотрение жизненной ситуации, сравнение нескольких высказываний, обсуждение картины (плаката, карикатуры), использование фрагмента видеофильма, незаконченные фразы (предложения, высказывания) и т.п.

Общие требования к мотивации на уроке:

- направленность на социальный опыт обучающихся или их интересы;
- возможность высказывать разные точки зрения;
- связь с изучаемой темой или определёнными вопросами;
- необычность формы или манеры подачи материала;
- доступность для понимания (простота языка и способа изложения);
- проблемность или дискуссионность.

Один из заключительных этапов современного урока это рефлексия. Рефлексия является не просто подведением итогов, а видением процесса и осознанием полученных результатов. Создаются условия для понимания того, что можно было бы изменить, знания об удачных способах действий [3]. Важно, чтобы студенты могли сформулировать основную идею, перечислить основные виды своей деятельности на уроке, ответить на вопросы: что нового узнали на занятии? Какой опыт приобрели в учебной деятельности? Что

было самым трудным на уроке? Что считают наиболее важным? Что было наиболее интересным?

Итак, какие требования предъявляются к современному уроку:

- хорошо организованный урок в хорошо оборудованном кабинете должен иметь хорошее начало и хорошее окончание;
- преподаватель должен спланировать свою деятельность и деятельность обучающихся, четко сформулировать тему, цель, задачи урока;
- урок должен быть проблемным и развивающим: преподаватель сам нацеливается на сотрудничество со студентами и умеет направлять их на сотрудничество с педагогом и между собой;
- преподаватель организует проблемные и поисковые ситуации, активизирует деятельность студентов;
- вывод делают сами обучающиеся;
- учет уровня и возможностей обучающихся, в котором учтены такие аспекты, как специальность, стремление, настроение студентов;
- планирование обратной связи;
- урок должен быть добрым.

Преподаватель должен опираться на принципы педагогической техники:

- свобода выбора (в любом обучающем или управляющем действии студенту предоставляется право выбора);
- открытости (не только давать знания, но и показывать их границы, сталкивать студента с проблемами, решения которых лежат за пределами изучаемого курса);
- деятельности (освоение студентами знаний, умений, навыков преимущественно в форме деятельности, студент должен уметь использовать свои знания);
- идеальности (высокого КПД (максимально использовать возможности, знания, интересы самих обучающихся);
- обратной связи (регулярно контролировать процесс обучения с помощью развитой системы приемов обратной связи).

СПИСОК ЛИТЕРАТУРЫ:

1. Дьюи Д. Педагогика: классические труды/пер. с англ. Ю.И. Турчаниновой и др. М.: Педагогика Пресс, 2000 г.
2. Йоффе А.Н «Структура современного урока истории и обществознания как основа организации деятельности учащихся», Преподавание истории в школе, №1 2012 г.
3. Михайловский О.С. Современные проблемы образования и географическая культура личности. /Человек и образование, № 4,5 2006г.

4. Требования к современному уроку географии. Матвеева М.Д, Анисимова С.П. Материалы Региональной школы-семинара. Томский государственный университет, 2002

ӘОЖ 37.004.31

ГЕОГРАФИЯНЫ ОҚЫТУДАҒЫ ОЙЫН ТЕХНОЛОГИЯЛАР: ТҮРЛІЛІГІ, ИНТЕРАКТИВТІЛІКІ ЖӘНЕ БІЛІМ БЕРУДЕГІ ПАЙДАСЫ

А.Ж.Жанибеков², Е.Н Сағатбаев¹

¹Астана халықаралық университеті Астана қ., Қазақстан
Ғылыми жетекші: м.а.қауымдастырылған профессор, PhG.
Жаратылыс ғылымдары жоғары мектебі

sagatbaeve@mail.ru

²Астана халықаралық университеті Астана қ., Қазақстан
3-курс студенті 6В01504- «География»
Педагогикалық институт

abdrahmandzhanibekov@gmail.com

Аннотация:Мақалада географияны оқыту процесінде ойын технологияларын тиімді пайдалану жолдары қарастырылады. Ойын тәсілдерінің алуан түрлілігі, олардың интерактивтілігі және оқушының білім беру тәжірибесін жақсартудағы артықшылықтарына назар аударылады. Мақалада географиялық білімді тереңірек және есте қалатындай үйренуге ықпал ететін ойын қолданбалары мен әдістерінің нақты мысалдары берілген.

Түйін сөздер: ойын технологиясы, географияны оқыту, әртүрлілік, интерактивтілік, білім беру тәжірибесі, ойын қолданбалары, әдістер, тереңдетіп оқыту, негізгі құзыреттер, компьютерлік бағдарламалар.

КІРІСПЕ

Қазіргі кезеңнен білім беруді ізгілендіру, ақпараттандыру – бүгінгі заман талабы. Ақпараттық білімнің, орта мен білім алушылардың өзара қарымқатынасын үйлестіруде және ақпараттық технологияны пайдалану қажеттілігінен туындап отыр. Өркениеттің өсуі ақпараттық қоғамның қалыптасуымен байланысты, қазіргі кездегі білім мен техниканың даму деңгейі әрбір адамға сапалы және терең білім мен кәсіби іскерліктердің болуын, жастардың белсенді шығармашылықпен жұмыс істеуін талап етеді. Осыған орай ақпараттық технологияда "Технология" сөзі грек тамырына ие және аудармада кез-келген қызмет саласында қолданылатын әдістер және процестер жиынтығын білдіретінін көреміз. Бұл жағдайда ақпаратты өңдеуге және түрлендіруге бағытталған технологияларды ақпараттық технологиялар деп санауға болады [1].

В. В. Давыдов оқушыларда танымдық проблемалық міндеттерді шештірудің жолдарын іздестіру арқылы шығармашылық тәжірибені меңгертуге болады, яғни соның нәтижесінде білім-білік, дағды дүниеге көзқарасын қалыптастыруды көздейді.

Ақпараттық технологияның қарқынды дамуымен ойын технологияларын оқу процесінде, әсіресе география пәнінің ажырамас бөлігіне ретінде қолдану қарастырылуда. Географияны оқытудағы ойын технологиялары: әртүрлілік, интерактивтілік және оқытудың тиімділігі ойын әдістерін білім беру тәжірибесіне енгізудің қазіргі тенденциялары мен перспективаларын қарастырамыз. Көрнекілік пен кеңістіктік ойлау басты рөл атқаратын география саласында ойын технологиялары оқушылар мен мұғалімдер үшін жаңа көкжиектер ашады. Осы тұрғыда біздің зерттеуіміз материалға кең көлемді енуді ғана емес, сонымен қатар оқытудың интерактивтілігін арттыруды қамтамасыз ететін әртүрлі ойын тәсілдерін анықтауға бағытталған.

Географияны оқытуда ойын технологияларын қолданудың тиімді стратегияларын көрсетуге тырысамыз. Мотивация, оқытуды жекелеңдіру және негізгі құзыреттіліктерді дамыту мәселелері біздің назарымызда, өйткені ойындар тек құрал ғана емес, сонымен қатар тереңірек және нәтижелі оқу үшін ынталандыру бола алатын маңыздылыққа ие.

Оқу үдерісіне жаңа технологияларды енгізуге байланысты қиындықтар бар. Географияны оқытуда ойын технологияларын сәтті енгізу үшін қандай кедергілер туындауы мүмкін және оларды қалай жеңуге болатынына назар аударған жөн.

Инновациялық әдістерді енгізу кезінде білім берудің алдында тұрған қиындықтары мен кедергілеріне оның шешіміне назар аудару қажет, сондықтан да оларды пайдаланудың ықтимал стратегияларын ұсынамыз. Қазіргі білім беру жағдайында технологияның өсіп келе жатқан рөлі оқыту әдістерінің үздіксіз эволюциясын қозғайды. Осы тұрғыда ойын технологиясы орталық орын алуда, оқыту тәсілдерін қайта анықтайды және оқу орындарын тартымды және тиімді оқу тәжірибесін құрудың қуатты құралымен қамтамасыз етеді.

Көрнекілік жағынан кеңістіктік зерттеуге мүмкіндігі мол география сабақтары ойын тәсілдерімен тәжірибе жасаудың бірегей өрісі болып табылады. Зерттеуіміздің бір бөлігі ретінде біз ойын әдістерінің әртүрлілігін және олардың білім беру тәжірибесін қалыптастыруға әсеріне назар аудардық.

Біздің мақсатымыз – бұл инновациялық технологиялар оқу үдерісін жай ғана толықтырып қана қоймай, түрлендіру, қызықты оқуды қамтамасыз

ету және оқушылардың географиялық материалмен белсенді әрекеттесуін ынталандыру.

Географияны оқытуда ойын технологиясын қолдану сабақтарды тартымды әрі тиімді өтуге болатынын атап өтетін болсақ.

Географиялық ойындар-кеңінен қолданылатын жаңа технологиялардың бірі. Географияны оқытуда ойын технологияларын қолдану оқушының сапалы білім алуына, яғни жеке тұлғаның өзін-өзі басқару қабілетін жетіліп әрі оқушы ақпаратты жеңіл тез қабылдауына мүмкіндік береді. География пәні ретінде мұғалімдер сабақтарды қызықты және тартымды етіп өткізуге болады. Географияны оқытуды үйрететін ойындар мықты құралы бола алады. Виртуалды географиялық квесттер, номенклатураны меңгеруге, басқатырғыштар, әлем картасын зерттеу, тарихи модельдеу және де тапқырлыққа, шығармашылыққа, оқушылар арасында ұйымшылдыққа бағыттай отыра ойын форматтары оқушыларға оқу процесіне белсенді қатысуға мүмкіндік береді.

Ойын технологияларын қолданудың артықшылықтарын қарастыратын болсақ. Ойын технологиясы оқушыларды оқу процесіне тартатын интерактивті ортаны құрайды. Олар географиялық мәселелерді шешуге ынталандырады, өйткені бұл ойын сценарийінің бір бөлігіне айналады. Алған білімді іс жүзінде қолдану арқылы ойындарда оқушылар географиялық білімді тәжірибеде қолдана алады, есептер шығара отырып дұрыс шешім қабылдайды, бұл жақсы оқуға ықпал етеді. Аналитикалық дағдыларды қалыптастыру барысында ойындар көбінесе ақпаратты талдауды, географиялық жұмбақтарды шешуді және әртүрлі факторлар арасындағы байланыстарды түсінуді қажет. Мысалы: Оқушылар интерактивті карта арқылы географияға қатысты сұрақтарға жауап беру үшін жарысатын виртуалды география викторинасын пайдалана алады. Қазіргі заманауи технологиялар оқушыларға сыныптан шықпай-ақ әлемнің әртүрлі жерлері мен аймақтарын зерттей алатын виртуалды саяхаттарға мүмкіндік береді. Бұл оларға басқа мәдениеттер мен ландшафттардың шынайылығына көруге мүмкіндік береді

Виртуалды экскурсияларды қолданудың артықшылықтары:

Реализм және белсенділікті артыру арқылы оқушылар өздерін басқа жерде жүргендей сезінеді, бұл олардың оқуға деген қызығушылығын артуына және де белсенді сабаққа қатысуына ықпал алады. Көрнекілік оқыту виртуалды далалық сапарлардағы көрнекі тәжірибелер географиялық ұғымдарды түсінуді айтарлықтай жақсартады. Мысалы: Ұлы Қытай қорғаны секілді орындарды виртуалды экскурсия жасау оқушыға осы тарихи орынды зерттеуге және оның географиялық сипаттамалары туралы білуге мүмкіндіктер тудырады.

Интерактивті қолданбалар мен білім беру платформалары бүгінгі таңда географияны оқыту үшін арнайы жасалған көптеген білім беру бағдарламалары мен платформалары кездеседі. Бұл қолданбалар жүйелі және дәйекті оқытуға ықпал ететін тапсырмаларды, викториналарды және интерактивті сабақтарды қамтамасыз ете алады.

Интерактивті қолданбаларды пайдаланудың артықшылықтары:

1. Жекелендірілген оқыту оқушыларға өз деңгейінде білім алумен қатар әсіресе қосымша тәжірибені қажет ететіндер үшін пайдалы.

2. Лездік кері байланыс арқылы қолданбалар оқушыларға қателіктерін жақсырақ түсінуге және оларды түзетуге көмектесетін жылдам кері байланыс береді. Мысалы: оқушыларға әртүрлі елдердің географиясын зерттеуге және білімдерін тексеру үшін викториналарды өткізуге мүмкіндік беретін білім беру қолданбасы. Географияны оқытуда ойын технологияларын қолдану сабақтарды қызықты әрі жүйелі етеді. Бұл оқушыларға белсенділігін, оқуға деген ынтасын және талдау дағдыларын дамытудың негізі болып табылады. Бұл тәсіл географияны оқу процесін қызықты әрі тиімді етеді, бұл осы әлемді тереңірек түсінуге ықпал етеді.

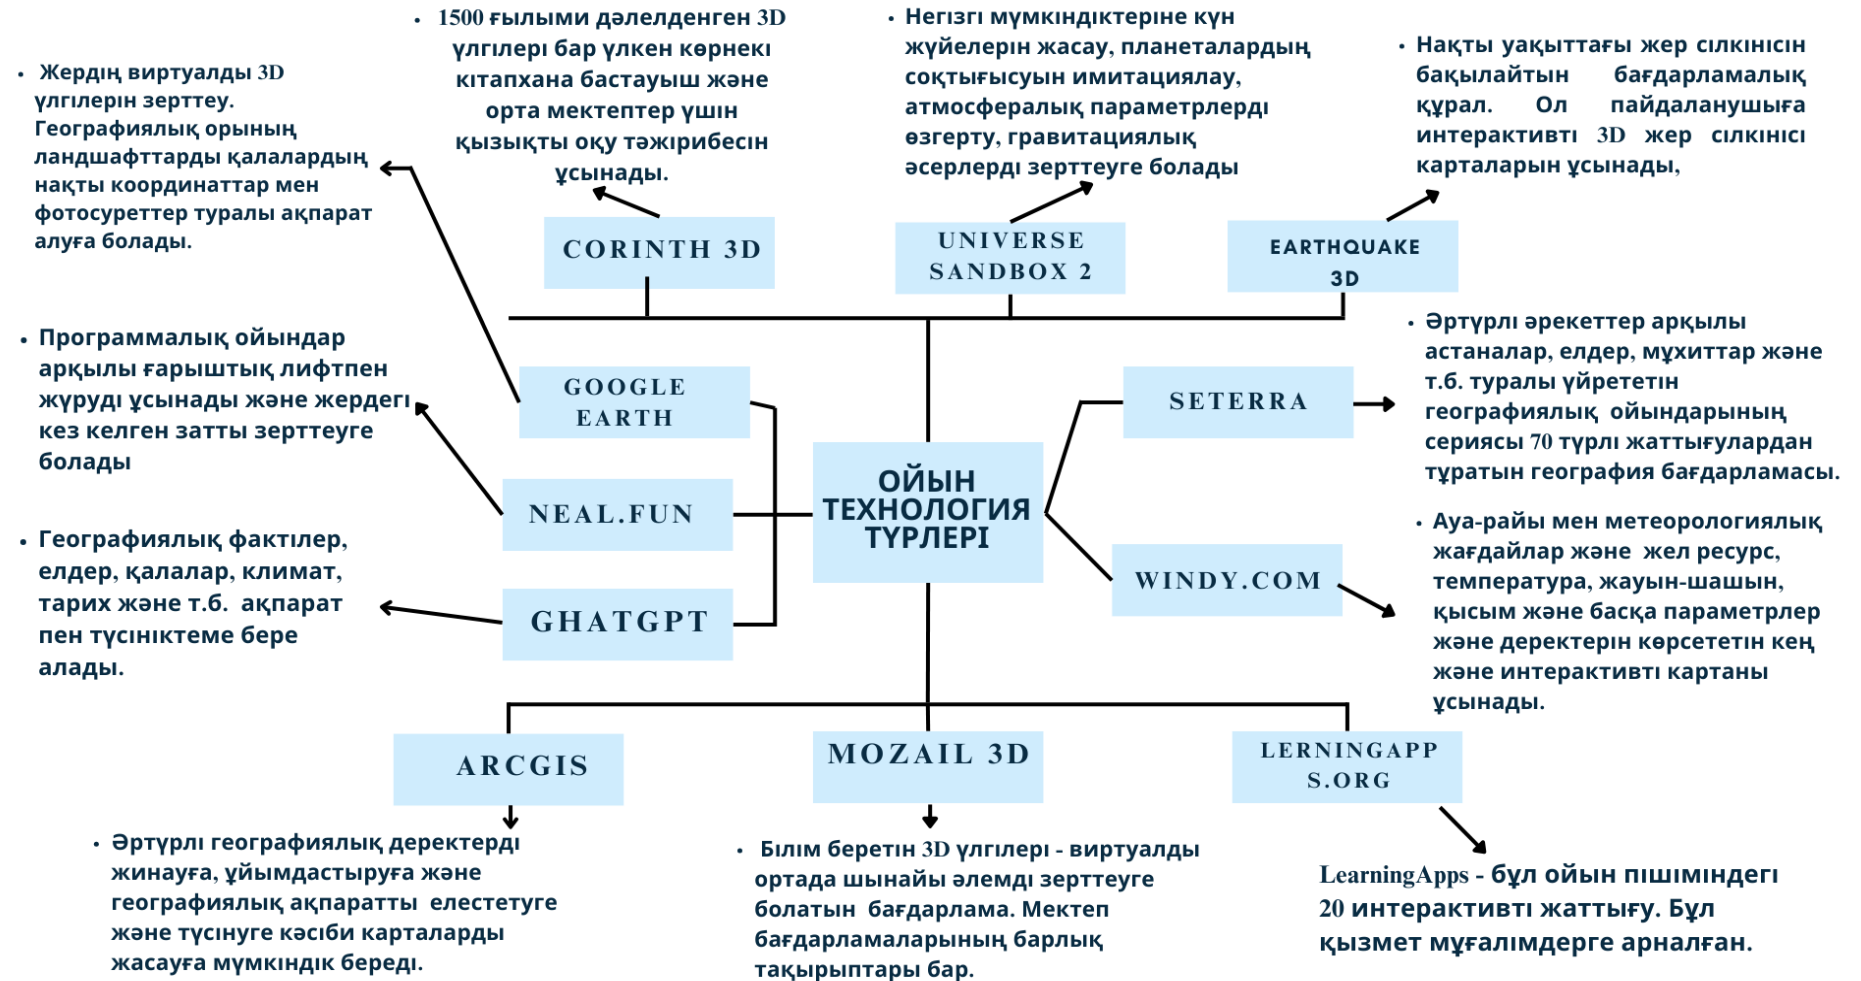
Кесте-1. Географиялық ойындар бойынша сабақ өткізу кезінде келесі талаптарға назар аудару керек.[2]

Оқу мақсаттары	География ойындары арқылы қол жеткізгіңіз келетін нақты оқу мақсаттарын анықтап алу. Мысалы, бұл әртүрлі елдердің астаналары мен географиялық ерекшеліктерін зерттеу немесе экологиялық мәселелерді түсіну болуы мүмкін
Жас және деңгейге бейімделу	Оқушылардың жасы мен білім деңгейін ескеру. Ойындар белгілі бір жас тобына сәйкес және қызықты болуы керек маңызды.
Интерактивтілік	Оқушыларды ынталандыру үшін ойындар интерактивті және қызықты болуы керек. Қатысуды ынталандыру үшін бәсекелестік пен марапат элементтерін қосуға болады. Уақыт мөлшері оқушыларды жалықтырмайтындай және де жоспар бойынша жүргізу керек.
Кері байланыс	Оқушылардың үлгерімі мен қателіктерін түсінуі үшін оларға кері байланыс беру. Бұл олардың қателіктерінен сабақ алуға сол қателікті жөндеуге көмектеседі.

Технологияларды біріктіру	Егер сіз компьютерді немесе мобильді қолданбаларды пайдалансаңыз, оқушыларды технологиямен таныс екеніне және қажетті жабдыққа қол жетімділігіне көз жеткізіп алу керек.
Шындықпен байланыс	Географиялық ойындарды шынайы әлеммен және өмірдегі жағдайлармен байланыстыруға тырысу. Бұл оқушыларға алған білімінің практикалық деңгейде қолданылуын көруге көмектеседі.
Мониторинг және бағалау	Оқушылардың үлгерімін бақылау және білім беру мақсаттарына жетуде ойындардың қаншалықты тиімді екенін түсіну үшін бағалау жүргізу.
Ойынның әртүрлілігі	Материалды үйренудің әртүрлі тәсілдерін қамтамасыз ету үшін басқатырғыштар, викториналар және модельдеу сияқты географиялық ойындарды қосу.
Жеке қажеттіліктерді қанағаттандыру	Оқушылардың жеке қажеттіліктері мен оқу стильдерін ескеру керек. Оқушылардың қажеттіліктерін ескере отыра жұмыс жасау тиімдірек болады.
Қауіпсіздік және қиындық	Интернет ресурстарын пайдалансаңыз, қауіпсіз онлайн тәжірибесін қамтамасыз етіңіз. Сондай-ақ, оқушылардың мүмкіндіктеріне сәйкес ойындардың қиындық деңгейін ретке келтіру керек.

Жоғарыдағы айтылған талаптарды ескере отырып, география сабақтарын ойындар арқылы тиімді және тартымды өткізе алуға болады.

Ойын технологиялардың түрлерін.



Сурет-1 Географияны оқытудағы ойын технологиялары

Кесте-2. Мұғалімдерге қажетті жасаңды интеллект құралдары [3]

Атауы	Қолданылуы
MagicSlides,Slidesal.io	(презентация жасауға арналған Google Slides көмекшісі)
LearningStudio AL	(онлайн курс жасай алатын ЖИ құралы)
MagicForm	(Викторина, сауалнама жасауға арналған Google Forms көмекшісі)
Media.io	(медиафайлдарды жақсартуға арналған құрал)
lessonplans.ai, Mindsmith	(Сабак жоспарын жасау)
jeda.ai	(онлайн тақта)
Quizbot	(сұрақ генераторы)
to teach	(жұмыс парақшалары мен сабақ жоспарларын жасау)
DALL•E	(мәтін арқылы сурет жасау)
Roshi	(оқу материалдарым жасау)
Copilot	(ЖИ көмегімен сабақ жоспарларын, викториналар мен жұмыс парақшаларын жасау)
Wordwall,Socrative,Quizizz,Kahoot, Mentimeter,educaplay,joyteka	Сабаққа ойындар жасауға арналған құралдар
Decktopus	(Презентация жасайтын нейрожелі)
Virbo	(Виртуалды аватар жасау)
Curipod	(интерактивті материалдар жасау)
Fliki	(сценарий арқылы видео жасау)
Smodin	(ЖИ көмегімен эссе жазу)
Fobizz tools	(мұғалімнің ақылды көмекшісі,жұмыс парақшалар, онлайн тақта, сауалнама, сурет

	және мәтінге арналған ЖИ көмекші т.б. құралдар)
TALKPAL AI	(тіл үйренуге арналған сервис)

Бұл технологияларды қолданумен қатар географияның әртүрлі аспектілерін интерактивті және көңілді түрде зерттеу үшін оқушыларға да, мұғалімдерге де қолайлы бола алады.

Интерактивті тренинг:

Ойын технологиясының интерактивті оқытуға және оқушылардың белсенділігіне айтарлықтай жақсартып алады оқушылардың оқу материалымен белсенді әрекеттесуіне мүмкіндік беретін тиімді әдіс. Ол терең түсіну мен оқуға ықпал ету үшін технологияларды, ойындарды, пікірталастарды және оқытудың басқа белсенді түрлерін пайдалануды қамтиды.

Оқытудың интерактивті әдістері оқушылардың қызығушылығын оятып, дараландыруды қамтамасыз етіп, оқушылардың сыни ойлауын дамытуға ықпал етеді. Ойындарда оқушыға белсенді қатысуға және мақсаттарға жетуге ынталандыратын жарыс, жетістік және марапат элементтері жиі болады. Көптеген білім беру ойындары қиындық деңгейін және мазмұнын әр оқушының жеке қажеттіліктеріне бейімдеуге мүмкіндік береді. Ойындар оқушылардың мазмұнмен өзара әрекеттесуіне, есептерді шешуіне, алған білімдерін практикада қолдануға мүмкіндік береді. Ойындарда қателіктерге жол беру оқушыларға тәжірибе жасауға, қателерінен сабақ алуға және сыни ойлауды дамытуға көмектеседі. Білім беру ойындары ынтымақтастық дағдыларын дамытуға көмектесетін топтық жұмысты қолайлы. Ойын технологиялары ақпаратты неғұрлым тартымды және көрнекі түрде ұсына алады, бұл күрделі ұғымдарды түсінуді жеңілдетеді

Білім беруде ойын технологиясын пайдалану оқу материалын қызықты және түсіну деңгейін арттыра отырып, оқу процесін қызықты және тиімді ете алады.

Ойын технологиясын, әсіресе география контекстінде пайдаланудың білім беру артықшылықтары.

Ойын технологиялары білім алушыларға материалмен белсенді әрекеттесу мүмкіндігін береді, бұл тереңірек білім алуға және сыни ойлауды дамытуға ықпал етеді. Географиялық ойындар географиялық білімді практикалық қолдану үшін контекст береді. Оқушының өздерінің дағдылары мен білімдерін өмірлік жағдайда қолдана алады, бұл олардың тақырып бойынша түсінігін нығайтады. Ойындарға кеңістікті қабылдау мен талдау

элементтері кіреді, бұл кеңістіктегі ойлау мен кеңістікте бағдарланудың дамуына ықпал етеді. Ойындар оқуға ынталандырады, өйткені олар көңілді және қызығушылық тудыруы мүмкін. Бұл оқушының мотивациясын арттырып, оқу үдерісін қызықты етеді.

Көптеген ойын платформалары оқуға жеке көзқарасты қамтамасыз ете отырып, қиындық деңгейін әр оқушыға бейімдеуге мүмкіндік береді. Кейбір ойын технологиялары ынтымақтастық пен топтық жұмысты қолдайды. Оқушылар топта жұмыс істеуге, пікір алмасуға, мәселелерді бірлесіп шешуге үйренеді. Ойын технологияларын қолдану барысында студенттерде қазіргі ақпараттық қоғамда маңызды болып табылатын заманауи технологиялармен жұмыс істеу дағдылары қалыптасады.

Бұл артықшылықтар ойын технологиясының білім беру тәжірибесін қалай байыта алатынын көрсетеді, оны қызықтырақ, тиімдірек және заманауи оқу қажеттіліктеріне сәйкес екендігін байқатады.

Кесте-3. Білім беруде ойын технологиясын қолданумен байланысты кедергілер мен қиындықтар

Кедергілер мен қиындықтар	Мәселе	Шешімі
Техникалық инфрақұрылымның жоқтығы:	Барлық мектептерде жеткілікті техникалық инфрақұрылымға қол жетімді емес, бұл ойын технологиясын енгізуді қиындатады.	Гранттар тарту, ақысыз немесе арзан білім беру платформаларына қол жеткізу және технологиялық компаниялармен бірлесіп жұмыс істеу бұл мәселені жеңуге көмектеседі
Мұғалімдердің дайындығының жоқтығы:	Көптеген мұғалімдердің оқытуда ойын технологияларын қолдану тәжірибесі жеткіліксіз болуы мүмкін	Мұғалімдерді жаңа технологияларға үйрету, семинарлар мен семинарлар ұйымдастыру және тәжірибе алмасу олардың құзыреттілігін арттыруға көмектеседі
Уақыттың жетіспеушілігі	Уақыттың шектеулілігіне байланысты мұғалімдерге қысым болуы мүмкін, бұл оқу бағдарламасына жаңа	Ойын технологиясын біріктіру қосымша жүктеме емес, бар оқу бағдарламаларының бөлігі болуы мүмкін. Сондай-ақ, процестерді жеңілдету және дайын білім беру

	технологияларды енгізуді қиындатады	ресурстарымен қамтамасыз ету мұғалімдердің уақытын үнемдейді
Оқушылардың мотивациясының проблемалары:	Ойынға негізделген тәсілдерге оқушылардың барлығы бірдей жауап бермейді, ал кейбіреулер үшін ойын алаңдататын нәрсе болуы мүмкін.	Ойындарды сыныпқа енгізу тәсілін саралау, сондай-ақ білім беру бағыты бар ойындарды таңдау бұл мәселемен күресуге көмектеседі.

Бұл қиындықтарды еңсеру әкімшілік қолдауды, мұғалімдерді оқытуды, ресурстар мен технологияларға қолжетімділікті және білім беру мекемелері мен технологиялық қауымдастық арасындағы үздіксіз әрекеттесуді қамтитын кешенді тәсілді талап етеді.

ҚОРЫТЫНДЫ

Географияны оқытуда ойын технологиясын қолдану оқу-тәрбие процесін байытудың перспективалық тәсілі болып табылады. Әртүрлі ойын тәсілдері интерактивтілікпен бірге оқушыларды баурап қана қоймайды, сонымен қатар географиялық білімді тиімдірек есте сақтауға және қолдануға ықпал етеді. Ойын қолданбалары мен әдістері арқылы жинақталған тәжірибе заманауи білім беру жағдайында білім алушылардың негізгі құзыреттіліктерін дамыту үшін құнды ресурс бола алады.

Географиялық білім беру контекстінде интерактивті оқытудың рөлін талдау нәтижесінде оқушылардың материалмен, ойындармен және технологиялармен белсенді әрекеттестігіне негізделген тәсілдердің оқу үдерісін жетілдіруде айтарлықтай мүмкіндіктері бар екенін көреміз. Интербелсенділік білімді тереңірек меңгеруге ғана емес, сонымен қатар осы білімді нақты жағдайларда қолдану дағдыларын қалыптастыруға ықпал етеді.

Бұл тәсіл сонымен қатар оқушылардың жеке қажеттіліктеріне жауап бере отырып, әртүрлі стильдер мен қарқындардағы оқытуды қолдайды. Ол әсіресе нақты білім ғана емес, сонымен қатар оны шығармашылық және аналитикалық тапсырмаларда қолдана білу маңызды болып табылатын заманауи білім беру ортасында пайдалы бола алады.

Осылайша, географияны оқытуда интерактивті әдістерді енгізу оқу процесінің тиімділігін арттырып қана қоймайды, сонымен қатар оқушыларға белсенділік, шығармашылық және күрделі мәселелерді шешу

қабілеті негізгі құзыреттілікке айналған қазіргі әлемде сәтті бейімделуге қажетті дағдыларды дамытады.

ӘДЕБИЕТТЕР

1. Казисова Д.Д., Мазбаев О.Б., Елеманова А.Б. Білім берудегі ақпараттық-коммуникациялық технологиялардың рөлі. "Шоқан оқулары-27: Аймақты дамытудағы университет ғылымының рөлі" арналған халықаралық ғылыми-практикалық конференциясының материалдары, Қазақстан, Көкшетау, 2023. Т. 2., - 794 б.

2. Қазіргі педагогикалық технологиялар пәнінің міндеті мен мақсаты. Педагогикалық технология түсінігі. <http://emirsaba.org/deris-azirgi-pedagogikali-tehnologiyalar-penini-mindeti-men-ma.html?page=52>

3. Жасанды интеллект білім саласында. Жасанды интеллект білім саласында by Erdos Ermurat (prezi.com)

СТЕВИЯ ӨСІМДІГІНІҢ БИОЛОГИЯЛЫҚ ЕРЕКШЕЛІКТЕРІ ЖӘНЕ КАЛУСТАН ӨСІРУ ЖОЛДАРЫ

Ж.А. Адамжанова¹, Н. С. Ауезова², Д.Е.Төлепберген³

1 ассоц. профессор, б.ғ.к

2 и.о ассоц. профессор, б.ғ.к

3 биология мамандағының 1-курс магистранты

Астана Халықаралық университеті(email:nurkuigan1971@mail.ru)

Аңдатпа: Стевия жапырақтарындағы дитерпенттік стевииолгликозидтерімен танымал. Негізгілері болып табылатын стевииозид және ребаудиозид А қазіргі тамақ өнеркәсібінде табиғи төмен калориялы тәттілендіргіштер ретінде кеңінен қолданылады, олардың тәттілігі сахарозаға қарағанда орта есеппен 250-300 есе жоғары. Стевия жапырақтарынан алынған сығындылар айқын антиоксиданттық қасиеттерге ие. Мақалада стевия өсімдігінің биологиялық сипаттамалары және өсімдікті каллустан өсіру жолдары туралы мәліметтер келтірілген. Стевия өсіру көлемін ұлғайту перспективалы болып табылады, өйткені көптеген аймақтарда экологиялық таза өнімдердің жоғары өнімін алу үшін жағдайлар бар және оны тамақ өнеркәсібінде кеңінен қолдану халықтың денсаулығын жақсартуға көмектеседі. Құрғақ жапырақ және тәтті гликозидтердің жоғары өнімін алу үшін қажетті жағдайлар, сонымен қатар зертханалық өсіру кезінде де, стевия дақылымен зерттеу жұмыстарын жүргізу кезінде де ескеру қажет факторлар қарастырылады.

Кілт сөздер: стевия, биологиялық сипаттама, тәтті гликозидтер, эксплант, каллус, гликозид, ауксиндер.

КІРІСПЕ

20-шы ғасырдың аяғы мен 21-ші ғасырдың басында қант диабеті мен семіздіктің тез өсуі физикалық белсенділіктің төмендеуінен және жоғары калориялы тағамдарды, соның ішінде тазартылған қантты шамадан тыс тұтынуға байланысты. Бұл бүкіл әлемде диеталық тәттілендіргіштер нарығының өсуін ынталандырады. Стевияның (*Stevia rebaudiana*) тәтті гликозидтері (стевииол гликозидтері, СГ) қазіргі уақытта табиғи ең перспективалы төмен калориялы тәттілендіргіштердің бірі болып табылады

Стевия (*Stevia rebaudiana* Bertoni) тұқыммен, сабақпен және тамырдың бөлінуімен көбейетін астралар тұқымдасына жататын қосжарнақты шөптесін өсімдік. Ол жақсы күтім жағдайында биіктігі шамамен 50-80 см, жылыжайда 130 см-ге дейін жетіп, бұта ретінде өседі [1].

Жоғары тазартылған СГ және ұсақталған құрғақ стевия жапырағы азық-түлік және фармацевтикалық нарықтарда, сондай-ақ косметологияда үлкен сұранысқа ие. СГ кондитерлік өнімдер (тосаптар, тәттілер және т.б.), шай, кофе, алкогольсіз сусындар, йогурт, жеміс шырындары, балмұздақ, маринадталған қияр, соя соусы, соя өнімдері және теңіз өнімдерін өндіруде кеңінен қолданылады. Сонымен қатар, олар тағамдық түстердің тұрақтандырғыштары, тіс пастасы қоспалары және қоюландырғыштар ретінде қолданылады. Стевия негізіндегі өнімдерге әлемдік сұраныс тұрақты өсуде. Алдағы онжылдықта стевия және оның өңделген өнімдерінің өндіріс көлемі нарық сұранысынан айтарлықтай төмен болады деп күтілуде. Сарапшылардың пікірінше, 2017 жылы стевия өнімдерін әлемдік сатудан түскен кіріс 490,1 миллион АҚШ долларын құрады және 2022 жылға қарай 700 миллион доллардан асады деп болжануда [2].

НЕГІЗГІ БӨЛІМ

Стевия өсімдігінің тамырлары тармақталып, топырақтың жоғарғы бөлігінде 25-35 см тереңдікте орналасады. Стивия өсімдігіне 1-3 өте тармақталған сабақтар тән, олар өз кезегінде жыл сайын өледі. Қысқа жасыл жапырақшалардан жартылай тармақталған тамырлар қалыптасады.

Стевия - жарық пен ылғалды жақсы көретін өсімдік, оның фотопериоды 13 сағат. Стевия өмірінің бірінші жылында және вегетациялық кезеңнің бірінші жартысында шілдеге дейін айтарлықтай баяу өседі, ал шілдеден қыркүйекке дейін оның өсуі тездейді және вегетативті массаның артуы байқалады. Келесі жылы жақсы тамырлары қалыптасады да стевия өсуді тездетеді және бір тамырдан 12-15 бүршік пайда болады. Стивияны сақтау үшін тамырды қазып, көктемнің басына дейін жертөледе сақтау ұсынылады. Сондай-ақ температура 5-10 ° C деңгейінде болуы қажет. Тамырлар кептіруден және шамадан тыс ылғалдан аулақ болу керек. Стевия қыста жарық болған кезде оянады және өсуін жалғастырады. Көктемгі күн сәулесі түскенде, стевияны жарыққа шығару керек. Өсімдіктің тамырсабағында жаңа өркен пайда болады, оны алуға және өсімдікті көбейтуге болады [3].

Стевия табиғи жағдайда Латын Америкасында өседі. Әдетте, плантацияларды өсірудің негізгі мақсаты дәстүрлі қантты алмастыра алатын

стевияның тәтті қасиеттерін алу болып табылады. Құрамында стевия бар азық-түлік өнімдері мен препараттарының энергетикалық құндылығы төмен және құрамында глюкоза тобы жоқ. Сондықтан стевияны үнемі тұтыну қандағы қант деңгейін арттырмайды. Стевия қант диабетімен ауыратындарға және салмақ жоғалтатын адамдарға ұсынылады. Стевияның қантқа қарағанда 50-300 есе тәтті екені және оны үнемі қолдансада денсаулыққа зияны жоқ екені дәлелденген. Стевия сығындылары тамақ өнеркәсібінде және үйде де көп мөлшерде қолданылады, өйткені олар пісіру және кондитерлік өнімдер үшін жақсы аспаздық қасиеттерге ие. Стевияны тұрақты түрде тұтыну денені нығайтады және тонусты жақсартады [4].

Стевия өсімдігінің артықшылығы - ол табиғи тәттілендіргіш шығарады. Адам ағзасында тәтті дитерпен глюкозидтері инсулиннің қатысуынсыз ериді және кейіннен оның секрециясын жасайды. Стевияның құрамында сау адамдарда қантты төмендететін әсері жоқ тәтті стевия гликозидтерінің болуына байланысты. А, В, С, Д, Е, дулькозид А және стевиол биосиді сияқты ребаудиозидтердің химиялық құрылымының ерекшеліктері дәлелденген. [5].

Стевияның құрамында қандағы қанттың сіңуін ынталандыратын хром бар. Осылайша, стевия инсулиннің жұмысын жеңілдетеді. Сондай-ақ оның құрамында селен мен мыс бар, олар теріге сау рең береді. Ағзада иммуномодуляциялық әсері бар мырыш стевияның құрамында бар. Оның құрамында В, С, РР дәрумендері де кездеседі, олар өз кезегінде ағзаға пайдалы. Бұл өсімдікті пайдалану қант диабетімен ауыратындар үшін маңызды. Ұқсас тәттілендіргіштерді пайдаланған кезде жанама әсерлер жиі пайда болады. Стевияда, керісінше, дененің жақсаруы және сауығуы байқалады. Стевияны шай сияқты қайнату ұсынылады, оны таблетка түрінде қолданбау керек, өйткені оларда қоспалар бар. Дәрігерлер стевияны аш қарынға тұтынуды ұсынбайды, өйткені ағза тәттілендіргішті дәстүрлі қант ретінде қабылдайды. Кейіннен инсулин өндіріледі, ол өз кезегінде майға айналады [6].

Стевия (*Stevia rebaudiana*) - қазіргі кездегі өсімдік шаруашылығында жас өнім. Қазақстанның агроөнеркәсіп кешенінде өзінің лайықты орнын алу үшін жеткілікті түрде зерттелмеген. Стевия өсіру айтарлықтай шектеулі, ал шын мәнінде жиналған жапырақтардың көлемі бірнеше ондаған тоннаға

жетеді. Бірақ бұл дақылдың үлкен бейімделу мүмкіндігі бар және вегетативті массадан жоғары өнім алуға қабілетті [7].

ЗЕРТТЕУ ӘДІСТЕРІ

Зерттеу объектісі ретінде стевияның (*Stevia rebaudiana*) стерильді микроөсімдіктері алынады, олардың көбеюі каллусогенез арқылы жүзеге асырылады (1-сурет). Каллус өсірудің маңызды факторы эксплант таңдау болып табылады. Ол үшін қоректік ортаны таңдау және өсіру жағдайлары басты рөл атқарады және зерттеу барысында өсімдік зарарсыздандырылып, содан кейін экспланттар бөліп алынуы қажет. Экспланттар өсіріліп, бастапқы каллус алынады.

Қолайлы орта жағдайында өсірілген экспланттан 4-7 апта ішінде бастапқы каллустар пайда болады. Каллусогенездің қалыптасуына ықпал ету үшін эксплант тінінің механикалық зақымдануы жасалады. Өйткені консистенциясы бос және жеке жасушаларға оңай ыдырайды. Өсу процесінде каллус ұлпа қабаттарын бұзып, кеңістікте дамиды.

Каллус жасушаларын алу кезінде әртүрлі өсімдік мүшелерінің ұлпа бөліктері таңдалады: экспланттар пробиркаларға, колбаларға және Петри табақшаларына гормондары бар жасанды ортаға орналастырылады.



Сурет 1.–*Stevia Rebaudiana* өсімдігінің сыртқы түрі

Стевияны культивирлеуде қолданылатын маңызды гормон - ауксин , ол жасушаның бөлінуін және ұзаруын белсендіреді. Жасуша ішіне енгеннен кейін гармон арнайы рецепторлармен байланысқа түседі, осылайша мембраналардың, рибосомалардың және ядролық аппараттың жұмысына

әсер етеді. Ауксиндер 2,4-дихлорфеноксисірке қышқылы (2,4-D), нафтилсірке қышқылы (НСК), индолил-3-бутир қышқылы (ИБК) және индолилсірке қышқылы (ИСК) 10 мг/л концентрацияда қолданылады. Каллус түзілу процесі жасушалар тобының тіндерінің дедифференциациясынан бұрын болады. Дедифференциация кезінде ұлпалардың өсімдіктегі ерекше қызметтеріне тән консистенциясы өзгеріп, жасушалардың бөліну күйіне оралады.

Бірқатар бөлінулерден кейін жасушалар жетілген каллус ұлпасы ретінде ұзарып өсе бастайды. Қартаю, бөліну және одан әрі өсу қабілетін жоғалатуы мүмкін, сондай-ақ каллус жасушаларының өлуін болдырмау үшін біріншілік каллус, яғни каллус ұлпасы 28-30 күннен кейін жаңа қоректік ортаға ауыстырылады және мәліметтер кестеге толтырылуы керек (1-кесте).

Кесте 1 – Каллустың даму кезеңдері

Каллустың даму кезеңдері, сипаттамасы	Тұқымдық культура басталғаннан соң 30 күннен кейін эмбриональды каллустан пайда болған сарғыш мөлдір эмбриоид	Эмбриондық каллус және эмбриоидтың глобулярлық кезеңі	Жүрек тәрізді эмбриоидтар	Стевия культурасынан алынған бүршік пен тамыры бар өскіндер
Өлшемі	-	-	-	-

Стевия өсімдігінің (*Stevia rebaudiana*) негізгі құндылығы оның табиғи тәттілендіргіштігі. Стевия жапырақтарында тәтті дитерпендік глюкозидтері бар, олар организмде инсулинсіз ериді және оның секрециясын ынталандырады. Қант диабетімен ауыратындарға арналған табиғи тәттілендіргіш, құрамында тәтті гликозидтер бар, стевия сау адамдарда қантты төмендететін әсерге ие емес.

ҚОРЫТЫНДЫ

Жұмыс барысында стевияның әдеби көздері мен пайдалы қасиеттері, сонымен қатар оның биологиялық және химиялық сипаттамалары зерттеледі. Оңтайлы температура мен фотопериодтық сағаттарды таңдау кезінде құрамында гормондар мен сахароза бар МС ортасында каллус алу процестері зерттеледі.

Жұмыс барысында стивиядан каллус алу үшін оңтайлы қоректік орта және зарарсыздандыру әдістері таңдалады.

Зерттеу нәтижелерінің арқасында бүршіктердің пайда болуын индукциялау, олардың өсуі және бүйірлік өркендерді қалыптастыру үшін өсіру режимдері анықталады: МС ортасы бойынша минералды тұздары бар қоректік орта, сондай-ақ фитогормондар кинетиннің мөлшері 0,2 мг/л және НСК 2 мг/л алынып, бұл жағдайларда көбею коэффициенті, тамыр жүйесінің қалыптасуы анықталады.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР

1. Базарнова Н. Г. Химия древесины и ее основных компонентов: Методическое пособие. – Барнаул : АГУ Барнаул, 2012г. – 136 с.
2. Angelini L.G., Martini A., Passera B., Tavarini S. Cultivation of *Stevia rebaudiana* Bertoni and associated challenges // Sweeteners. Reference Series in Phytochemistry / Ed. by J.M. Mérillon, K. Ramawat. – Springer Cham, 2018. – Pt. 1. – P. 35–85. – doi: 10.1007/978-3-319-27027-2_8
3. Кедик С. А. Контроль качества и критерии стандартизации сухого очищенного экстракта из листьев стевии // Вопросы биол., мед. и фарм. Химии, 2018. – № 2. – 23 с.
4. Комиссаренко Н. Ф. Дитерпеновые гликозиды и фенилпропаноиды листьев *Stevia rebaudiana* Bertoni // Растительные ресурсы, 2014. – Т. 30. – С. 53–64.
5. Полудённый Л. В., Журавлёв Ю. П. Заготовка, выращивание и переработка лекарственных растений, 2008. – 276 с.
6. Яшин А. Я. Новый прибор для определения антиоксидантов в лекарственных препаратах, биологически активных добавках, пищевых продуктах и напитках Цвет Яуза-01-АА. – М. : НПО «Химавтоматика», 2005. – 75 с.
7. Федотов В. А., Коломейченко В. В., Верзилина Н. Д. Растениеводство Центрально-Черноземного региона: учебник для студентов высших учебных

заведений по агрономическим специальностям. – Воронеж : Центр духовного возрождения Черноземного края, 2018. – 65 с.

8. Singh D.P., Kumari M., Prakash H.G., Rao G.P., Solomon S. Phytochemical and pharmacological importance of stevia: A calorie-free natural sweetener // Sugar Tech. – 2019. – V. 21, No 2. – P. 227–234. – doi: 10.1007/s12355-019-00704-1.

ИСПОЛЬЗОВАНИЕ ТЕСТОВ И ТЕСТОВЫХ ЗАДАНИЙ В ПРОЦЕССЕ УПРАВЛЕНИЯ КАЧЕСТВОМ УРОКОВ ПО ХИМИИ

Б.Н. Бекмаханбет¹, Д.А. Нурғалиева²

¹магистрант образовательной программы «7М01503-Химия», 2 курс

²к.п.н., доцент ПИ. Международный Университет Астана.

Астана, Казахстан

Аннотация: В данной статье дана оценка учебных достижений учащихся, являющееся обязательным компонентом каждого урока. Они могут быть использованы на всех этапах процесса обучения и рассматриваться как система, которая обеспечивает структурирование содержания учебного материала, отбор форм, приемов и методов обучения в соответствии с этими особенностями. Актуальность данной проблемы заключается в широком использовании в настоящее время тестов и тестовых заданий для выявления результатов обучения, связанными с модернизацией и изменением направлений развития современного образования в Казахстане.

Ключевые слова: тестовые задания, химия, входной и выходной контроль, оценка учебных достижений

Оценка учебных достижений учащихся - неотъемлемый элемент каждого урока. Эта практика может быть интегрирована на всех этапах образовательного процесса и рассматриваться как система, которая не только структурирует содержание учебного материала, но и определяет выбор форм, методов и приемов обучения в соответствии с индивидуальными особенностями учащихся. Постоянное совершенствование системы контроля и оценки знаний на урока - задача для каждого преподавателя.

Актуальность проблемы обусловлена широким использованием тестов и тестовых заданий для выявления результатов обучения. Это объясняется объективными причинами, связанными с модернизацией и изменением направлений развития образования в РК, а также внедрением внешнего независимого оценивания.

Внедрение тестового контроля при обучении значительно увеличивает мотивацию и интерес учеников к учебному процессу. Тестовые задания удобны для использования на всех этапах урока. Преподаватель может оценивать уровень усвоения ключевых элементов учебного курса, выявлять

пробелы в знаниях, а также определять задачи для продуктивного самостоятельного обучения и планирования этапа коррекции знаний.

Тестирование является не только средством контроля, но и учебным упражнением. Использование тестовых заданий в качестве инструмента обучения эффективно и обосновано с точки зрения дидактики и психологии. Четко определенные процедуры тестирования и наличие эталонов позволяют оптимизировать учебный процесс, а фокус на активной мыслительной деятельности и объективности результатов способствует формированию положительного отношения у школьников к предмету, такому как химия[1].

И.Я. Лернер подчеркивает, что тесты выполняют не только контрольную, но и учебно-развивающую функцию, дополняя плановый контроль, такой как устный опрос и письменные контрольные работы. Они разнообразят процесс проверки усвоенных знаний, умений и навыков, активизируют овладение языковым материалом путем сознательного выбора, анализа и сопоставления. Тесты также стимулируют активность и внимание учеников во время занятий, повышая их ответственность при выполнении поставленных задач. Важно отметить, что тесты не заменяют плановый контроль, а дополняют его, придавая обучению дополнительные аспекты [2]. В зависимости от образовательных целей применяются разнообразные формы контроля знаний. В исследовании В.С. Аванесова подчеркивается, что для каждого из традиционных типов контроля (входного, текущего, тематического, периодического и итогового) используются тесты с различным структурным оформлением [3].

Так, работая в образовательном центре «Достык», г. Караганда, мною, для выявления уровня знаний по пройденным темам у учащихся 11 классов, проводится тест по общей химии, результаты которых, отображены в таблице.

Тестовые задания:

1) Слабый электролит

A. Серная кислота

B. Азотная кислота

C. Угольная кислота

D. Соляная кислота

E. Раствор бромоводорода

2) Элемент положение которого не соответствует правилу

Клечковского

A. Mg

B. Cl

C. Na

D. Cu

E. Ti

3) Определите массу растворенного вещества в 250г 30%-ного раствора

A. 25

B. 55

C. 75

D. 95

E. 105

4) Главное квантовое число n

A. *Описывает энергию*

B. *Направление в пространстве*

C. *Вращение электронов*

D. *Форму орбитали*

E. *Число электронов*

5) Элемент с 3-мя неспаренными электронами в нормальных условиях

A. N

B. O

C. S

D. Cl

E. Ne

6) Не относится к свойствам ковалентной связи

A. *Насыщаемость*

B. *Поляризуемость*

C. *Ионизация*

D. *Направленность*

E. *Летучесть*

7) Соединение с короткой длинной связью

A. Cl₂

B. H₂

C. N₂

D. O₂

E. I₂

8) Геометрия молекулы SF₄

A. *Правильный треугольник*

B. *Качели*

C. *Тетраэдр*

D. *Угловая*

E. *Бипирамида*

-
- 9) Вещества с внутримолекулярными водородными связями
- A. Углеводы
 - B. Белки
 - C. Липиды
 - D. Спирты
 - E. Кетоны
- 10) sp^2 гибридизация характерен для
- A. NH_3
 - B. $BeCl_2$
 - C. SO_2
 - D. CO_2
 - E. H_2O
- 11) Групповой реагент, используемый для определения слабых кислот
- A. H^+
 - B. NH_4^+
 - C. Ca^{2+}
 - D. Ba^{2+}
 - E. K^+
- 12) Масса хлорида натрия в 0,3М 5л раствора (г)
- A. 29.2
 - B. 58.5
 - C. 87.8
 - D. 119
 - E. 127
- 13) Лаборант смешал 450г 15%-го и 600г 55%-го раствора уксуса. Определите долю растворенного вещества в получившемся растворе(%)
- A. 21,77
 - B. 28,64
 - C. 37,86
 - D. 43,23
 - E.
- 14) Расчитайте молярную концентрацию 400 мл раствора, содержащего 0,4 моль кислоты
- A. 1М
 - B. 2М
 - C. 3М
 - D. 4М
 - E. 5М
-

-
- 15) Количество соли в растворе объемом 0,25л и молярной концентрацией 3M
- A. 0.25M
 - B. 0.50M
 - C. 0.75M
 - D. 1.00M
- 16) Подуровень заполняемый после уровня 6s
- A. 5p
 - B. 4d
 - C. 4f
 - D. 6p
 - E. 6d
- 17) Соединение с ковалентно неполярной связью
- A. O₂
 - B. HCl
 - C. NH₃
 - D. H₂O
 - E. HI
- 18) Тип гибридизации в молекуле SO₃
- A. sp
 - B. sp²
 - C. sp³
 - D. sp³d
 - E. sp³d²
- 19) Элемент с наибольшим атомным радиусом
- A. Na
 - B. K
 - C. Rb
 - D. Cs
 - E. Ca
- 20) Определите правильное утверждение о соединениях с ионной кристаллической решеткой
- A. Летучий
 - B. Тягучий
 - C. Не растворимый в воде
 - D. Твердый

Таблица. Данные о полученных баллах

Ф.И.О	Набранный балл
Къзыма Марлен	13
Талгатулы Асхат	21
Оразов Елдаулет	10
Кабкенов Айса	11
Кузнецов Даниил	15
Нұрұмжан Нұрқасым	20
Мысыр Арсен	20
Шырынхан Айдархан	14
Умаров Мирас	19
Қанағат Қайрат	17

Оценивание знаний и умение обучаемых с помощью тестирования, проводимого при входном и выходном контроле, в зависимости от целей, может выполнять как стимулирующую, так и контрольную функцию. Первая имеет место при самооценке, вторая – при оценивании результатов.

Самопроверку учащимися результатов тестирования рекомендуем проводить при осуществлении выходного контроля по итогам учебных достижений, в процессе овладения новыми знаниями и умениями.

Для оценивания результатов любого из видов тестирования предлагаем расчет коэффициента эффективности усвоения учебного материала:

$$K_{\text{усв}} = (x-y)/x * 100\%,$$

где x- количество тестов или утверждений, y- количество ошибок.

Для выставления оценок (по результатам тестирования), используем шкалу 10-бальной оценки. Подобное процентное распределение значений $K_{\text{усв}}$, по баллам обусловлено различной степенью сложности выявления правильного ответа на тестовое задание и коррелирует с вероятностью случайного ответа.

Анализ наблюдений за тестовой формой оценивания знаний и умений учащихся и ее результатов показал, что использование тестирования в обучении является эффективным методом для укрепления и расширения знаний учащихся.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Дуженков, В.Д. Деякі аспекти методики складання тестових завдань / В.Д. Дуженков, Т.І. Панасюк // Організація навчально-виховного процесу. 2006. — Вип. 8. — С.104–109.
2. Лернер, И.Я. Показатели системы учебно-познавательных заданий / И.Я. Лернер // Новые исследования в педагогических исследованиях. — М.: Педагогика, 1990. — Вып. 2. — с. 3–74.
3. Аванесов В.С. Методологическое и теоретическое обоснование тестового педагогического контроля: дис. На соискание учёной степени доктора пед. наук / В.С. Аванесов. — СПб.: Госуниверситет, 1994. — с. 205–214.
4. Н.В. Коренькова, А.Э. Кореньков Способы оценивания учебной деятельности студентов/ Оценивание: образовательные возможности. Сборник научно-методических статей.- Минск, 200 .-Вып.4.-с.133

ОПРЕДЕЛЕНИЕ УРОВНЯ ШУМА В УЧЕБНЫХ АУДИТОРИЯХ МЕЖДУНАРОДНОГО УНИВЕРСИТЕТА АСТАНА

Ш.Қ.Кәрім, А.С.Сейтқан

Студент 4 курса, ОП 6В05201- Экология и природопользование

К.т.н., доцент Высшей школы естественных наук

Международного университета Астана

Аннотация. В статье представлены результаты исследования уровня шума в учебных аудиториях Международного Университета Астаны акустическим методом. Исследование выявило, что уровень шума в аудиториях, с видом на проезжую часть, превышает гигиенические нормативы. Также, предложены рекомендации по оптимизации акустической среды в учебных помещениях для создания более комфортной и здоровой образовательной среды для студентов.

Ключевые слова: шум, акустическое измерение, гигиенические нормативы, учебные заведения, эквивалентный уровень шума.

ВВЕДЕНИЕ

Шум – это явление, которое зачастую недооценивается и игнорируется в современном мире. Звуковой уровень в диапазоне 20–30 дБ обычно считается безопасным и является частью естественного шумового фона, который необходим для нормальной жизнедеятельности человека.

Согласно нормативам Всемирной Организации Здравоохранения (ВОЗ), при постоянном воздействии шума по ночам в 50 дБ или выше у человека могут возникнуть сердечно-сосудистые заболевания. Шума громкостью 35 дБ достаточно, чтобы человек ощутил раздражение, 42 дБ - вызывают бессонницу. По данным ВОЗ, тысячи людей по всему миру умирают из-за сердечных расстройств, обусловленных постоянным действием повышенного уровня шума [1].

Известно, что шум в учебных аудиториях является одним из значимых факторов и порой может достигать крайне высоких значений. Доказано, что шум может негативно сказываться на здоровье студентов, ухудшать их внимание и концентрацию во время учебных занятий, что может отразиться на общей академической успеваемости студентов [2].

Одним из основных источников шума в учебных заведениях является внешний шум, включая шум от дорожного движения и авиатранспорта. Внешние источники включают дорожный трафик, который является значительным фактором шума, особенно для учебных зданий, расположенных вблизи оживленных дорог. Шум от строительных работ также вносит весомый вклад, особенно если рядом с учебным заведением ведутся активные строительные мероприятия. Кроме того, различные коммерческие и развлекательные заведения, расположенные недалеко от учебных учреждений, могут создавать дополнительные шумовые фоны. Исследования показывают, что даже небольшое повышение уровня шума может снизить понимание прочитанного у детей. Например, повышение уровня шума от авиатранспорта на 5 дБ может привести к задержке в чтении на один месяц в Нидерландах и на два месяца в Великобритании [3]. Также существуют проблемы, связанные с вниманием, памятью и мотивацией, при значении уровня шума в 60дБ [4]. В исследовании малазийских ученых посвященном шумовому загрязнению окружающей среды университетов, было выявлено, что шумовое загрязнение вокруг учебных заведений негативно влияет как на преподавателей, так и на студентов, и что приемлемый уровень шума в университетской среде должен составлять от 35 до 50 дБ(А) [5].

Внутренние источники шума также могут существенно влиять на учебную среду. К ним относятся шум от работающих в классах проекторов, компьютеров, а также разговоры и шумы, создаваемые самими учениками. Сохранение качества речи и понимания на уроках зависит как от уровня шума, так и от его характеристик, таких как отражение звука в помещениях. Акустика в классе - важный аспект учебной среды, которым часто пренебрегают. Несоответствующие уровни фонового шума, реверберации и соотношения сигнал/шум могут негативно сказаться на способности к чтению и правописанию, поведению, внимании, концентрации внимания и успеваемости. Громкие или гулкие классы могут заставить учителей повышать голос, что приводит к повышенному стрессу и усталости учителей, а также к риску нарушения голоса [6].

Кроме того, значительный шум может исходить от систем отопления, освещения и вентиляции. Эффективность обучения может снижаться не только из-за прямого воздействия шума на слух, но и из-за общего ухудшения акустической среды, что делает трудным восприятие учебного материала. Исследования показывают, что до 70% студентов университетов испытывают трудности в концентрации внимания из-за шума, что приводит к раздражению, раздражительности и потере внимания. Ненадлежащие условия, такие как шум в учебных помещениях, существенно влияют на обработку информации во время занятий, а также на академическую успеваемость и общее здоровье студентов. [7].

Согласно Приказа Министра здравоохранения Республики Казахстан от 16 февраля 2022 года «Об утверждении Гигиенических нормативов к физическим факторам, оказывающим воздействие на человека», предъявляются строгие требования к уровню шума в учебных заведениях - 55 дБ [8]. Для обеспечения комфортной и здоровой образовательной среды важно изучать акустическую обстановку - знать уровень шума в аудиториях вузов.

Акустическая обстановка в учебных аудиториях Международного университета Астана ранее не была изучена. Цель данной работы - определение уровня шума в учебных аудиториях Международного Университета Астана.

МЕТОДИКА ИССЛЕДОВАНИЯ

Аудитории для измерения шума были выбраны с учетом их расположения - расстояния от прилегающих к университету автомобильных дорог. На рисунке 1 приведена наглядная схема расположения аудиторий 305, 308, 344, 345, 311.

Окна аудитории 305 выходят на проспект Кабанбай Батыра, который характеризуется большим трафиком, особенно, в часы пик. В то время как аудитория 308 имеет окна с видом на улицу Атасу, где транспортное движение менее интенсивно. Окна аудиторий 344 и 345 ориентированы на задний и передний дворы университета, отдаленные от транспортного шума. Анализ акустических условий в этих помещениях позволит оценить

внутренний шум, издаваемый обучающимися в ходе учебного процесса. Аудитория 311, расположенная в непосредственной близости с open space, подвержена воздействию как внешних, так и внутренних шумов.

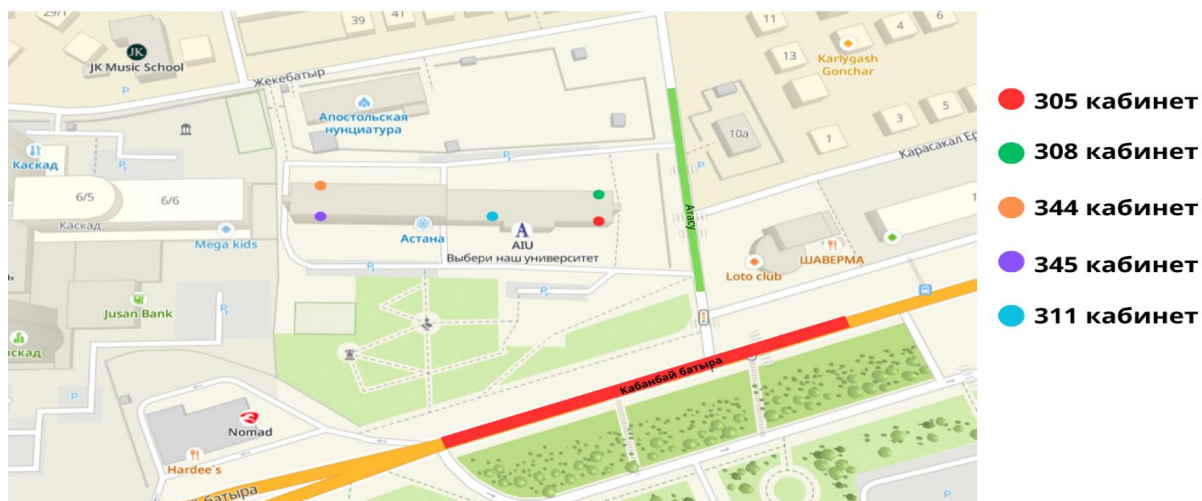


Рисунок 1 – Схема расположения учебных аудиторий

Акустические измерения осуществлялись с помощью цифрового шумомера MS6702 по методике ГОСТ ISO 9612—2016 «Акустика. Измерения шума для оценки его воздействия на человека. Метод измерений на рабочих местах», введенной в 2020 г [9]. Измерения проводились в апреле 2023 года в течение одной недели. Полученные данные анализировались и сравнивались с гигиеническими нормативами [8].

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Результаты проведенных акустических измерений приведены на рисунках 2-6. На рисунках видна динамика изменения интенсивности уровня шума. Проведенный анализ эквивалентного уровня шума в аудиториях 305 (рисунок 2) и 308 (рисунок 3) выявил, что в течении учебных занятий наблюдается превышение нормы по уровню шума. Максимальное значение достигало 62,3 дБА, а в 308 аудитории на 57дБА, что не соответствует гигиеническим нормативам.

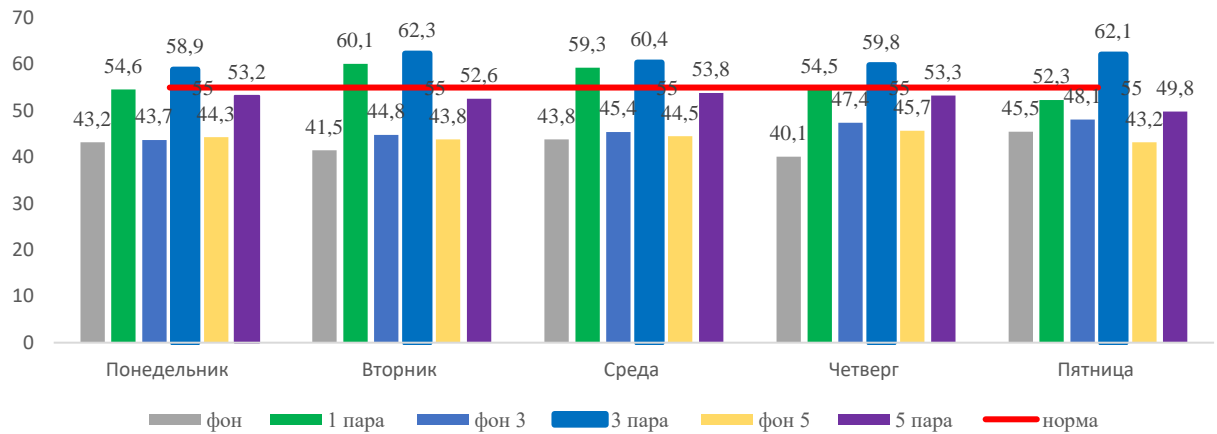


Рисунок 2 – Эквивалентный уровень шума в аудитории 305

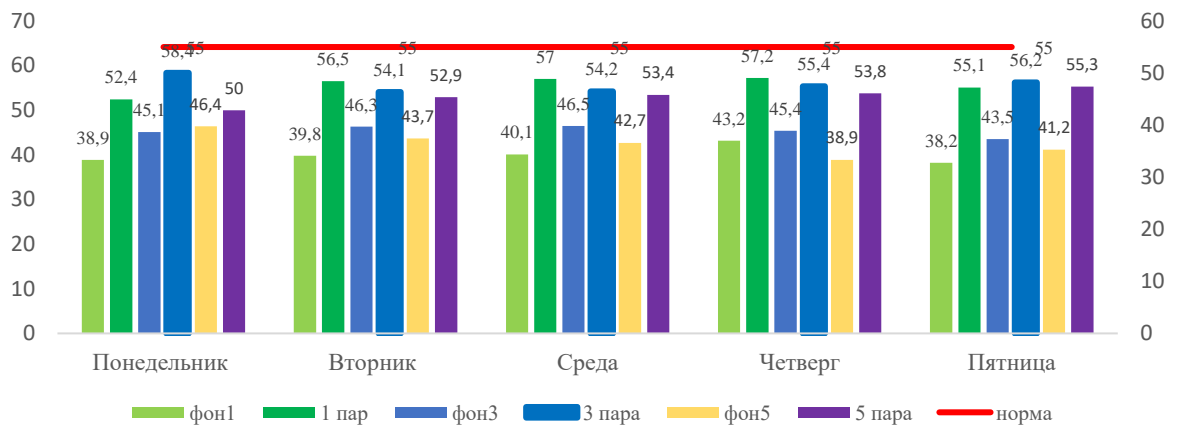


Рисунок 3 – Эквивалентный уровень шума в аудитории 308.

Также было выявлено, что в подавляющем большинстве случаев превышение норматива наблюдается во время третьей пары, что может быть связано как с большим количеством студентов в университете в это время, так и с интенсивностью дорожного движения по проспекту Кабанбай батыра. Наименьшие показатели были зарегистрированы в пятницу к вечеру, что коррелирует с уменьшением активности /количества студентов в университете. В аудитории 308, с окнами, выходящими на менее оживленную улицу Атасу, уровень шума оставался более стабильным и предсказуемым на протяжении всей недели. Наибольший уровень шума отмечался в середине дня, что согласуется с ритмом активности студентов, особенно в перерывах между занятиями (измерения шума до начала занятий).




Рисунок 4 – Эквивалентный уровень шума в аудитории 344

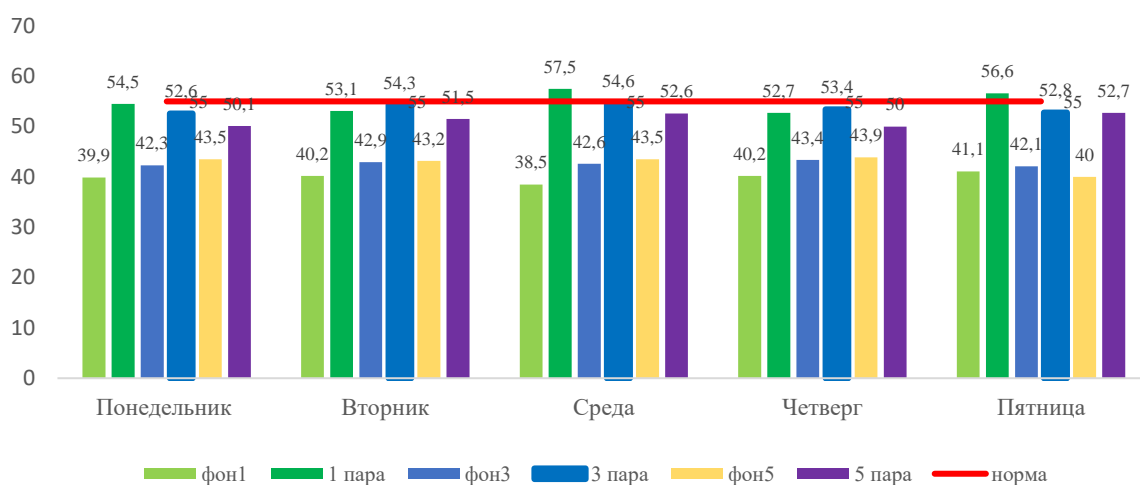


Рисунок 5 – Эквивалентный уровень шума в аудитории 345.

Во ходе анализа уровней шума в аудиториях 344 (рисунок 4) и 345 (рисунок 5) университета было установлено, что превышение гигиенических норм наблюдается не так часто по сравнению с аудиториями 305 и 308. Однако было зафиксировано два случая превышения нормы, что мы связываем с активностью студентов во время данных занятий.

Во всех измерениях, произведенных в течение недели во время 1 и 3 пар в 311 аудитории, эквивалентный уровень шума превышал гигиеническую норму по шуму (>55дБА) (рисунок 6). В частности, наибольшее значение было зафиксировано во вторник на третьей паре, где количество студентов в аудитории было максимальным (22 студента). Так же близость open space к

аудитории 311 могло оказать существенное влияние на повышенный уровень шума.

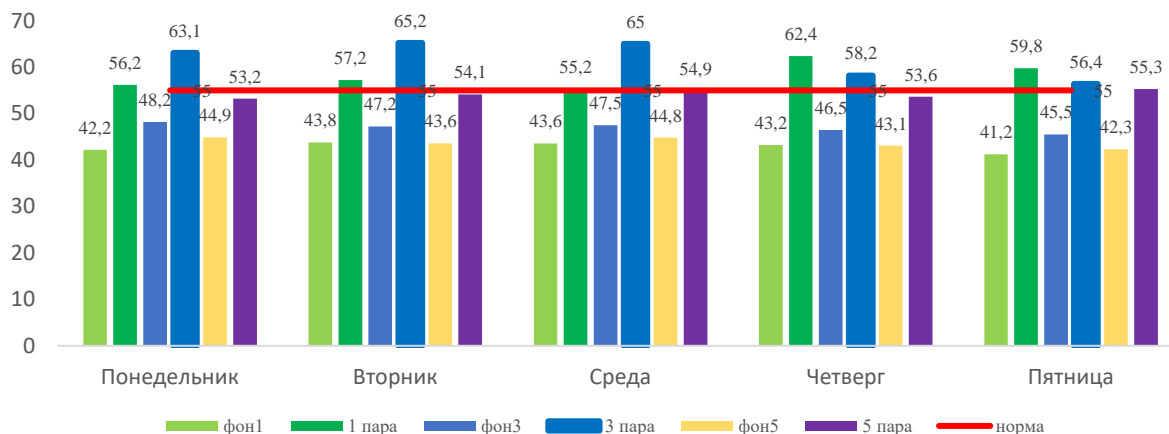


Рисунок 6 – Эквивалентный уровень шума в аудитории 311

Анализ результатов акустических измерений свидетельствует о том, что уровень шума в аудиториях, выходящих на проезжую часть (например, аудитории 305 и 308), в целом, выше, чем в аудиториях, находящихся в удалении от транспортного потока (например, 344 и 345). Это подтверждает важность учета факторов внешней среды при планировании учебного процесса и обеспечения акустического комфорта в учебных заведениях.

Во всех аудиториях наблюдалась взаимосвязь между эквивалентным уровнем шума и количеством студентов, что указывает на формирование шума за счет активности студентов.

Эквивалентный уровень шума колеблется в течение дня и недели, с пиковыми значениями, как правило, в середине дня во время третьей пары в большинстве случаев. Также стоит отметить, что наблюдается заметная тенденция к снижению шума к концу учебного дня на пятой паре. Это снижение может быть обусловлено как с меньшим количеством студентов во время пятой пары, так и с сокращением активности и возрастающей утомляемостью студентов к концу дня.

На основе проведенного исследования были разработаны следующие рекомендации для поддержания оптимального уровня шума в учебных аудиториях университета:

1. Для аудиторий с видом на улицы с большой транспортной нагрузкой, необходимо рассмотреть установку шумозащитных окон – окна со специальными вентиляционными устройствами, обеспечивающими повышенную звукоизоляцию при одновременном обеспечении нормативного воздухообмена в помещении.
2. Планировать размещение зон общего пользования (open space) в более отдаленном от учебных аудиторий местах или применять звукопоглощающие материалы для отделки таких зон.
3. Проведение семинаров или лекций по повышению осведомленности студентов о вреде шумового воздействия на организм человека и важности акустической обстановки для концентрации внимания и повышения учебной эффективности студентов.
4. Проведение регулярного мониторинга уровня шума в учебных аудиториях.

ЗАКЛЮЧЕНИЕ

Впервые был измерен уровень шума в учебных аудиториях Международного университета Астана. Зафиксированные высокие значения, превышающие гигиеническую норму, указывают на необходимость улучшения акустической обстановки в учебных аудиториях.

На основе проведенного исследования были разработаны рекомендации по оптимизации акустической среды в учебных аудиториях университета для обеспечения здоровой и комфортной образовательной среды для студентов.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. World Health Organization. Regional Office for Europe (2022). Night noise guidelines for Europe. World Health Organization. Regional Office for Europe. URL: <https://iris.who.int/handle/10665/326486>;

2. Shield B. M., Dockrell J. E. The effects of environmental and classroom noise on the academic attainments of primary school children // The Journal of the Acoustical Society of America. – 2008. – Т. 123, № 1. – С. 177-188.
3. Shield, B., Conetta, R., Dockrell, J., Connolly, D., Cox, T., Mydlarz, C. A survey of acoustic conditions and noise levels in secondary school classrooms in England // The Journal of the Acoustical Society of America. – 2015. – Т. 137, № 1. – С. 177-188
4. Hygge, S. Summary of the nonauditory effects of noise on children's health / Bistrup M.L., Keiding L. (eds.). – Copenhagen: National Institute of Public Health, 2002. – С. 1628-1628.
5. Haj, Z.H., Richard, H.K. Noise Pollution at School Located in Residential Area // Journal of Kejuruteraan Awam (Journal of Civil Engineering). – 2000. – Т. 12, № 2.
6. Acoustics in Schools. Ceilings & Interior Systems Construction Association. InformeDesign, Minnesota, USA; 2009.
7. Emilse Aparecida Merlin Servilha, Marina de Almeida Delatti. College students' perception of classroom noise and its consequences on learning quality. *Audiol Commun Res.* 2014;19(2):138-44. URL:<http://dx.doi.org/10.1590/S2317->
8. Министр здравоохранения Республики Казахстан. (2022). Приказ от 16 февраля 2022 года № ҚР ДСМ-15.
9. ГОСТ ISO 9612-2016. Акустика. Измерение шума для оценки его воздействия на человека. / М.: Стандартинформ, 2016 - 45 с.

БАЙЕСОВСКАЯ ПАРАДИГМА В НЕЙРОННЫХ СЕТЯХ

Н. Досанов¹, А. Ерланұлы², Е. Алданов³

¹докторант, ²магистрант, ³асс.профессор
Международный университет Астана

Было предложено множество подходов для снижения риска прогнозирования, особенно с помощью использования стохастических нейронных сетей для оценки неопределенности в прогнозировании модели. Байесовская парадигма обеспечивает строгую основу для анализа и обучения таких стохастических нейронных сетей и, в более общем плане, для поддержки разработки алгоритмов обучения.

Байесовская парадигма основана на двух простых идеях. Во-первых, вероятность – это мера доверия появлению событий, а не просто некоторый предел частоты появления, когда количество выборок стремится к бесконечности. Во-вторых, априори убеждения влияют на апостериорные убеждения. Все это резюмируется теоремой Байеса, очень простой всем известной формулой (1) для обращения условных вероятностей, и ее интерпретацией в байесовской статистике.

$$P(H|D) = \frac{P(D|H) \cdot P(H)}{P(D)} = \frac{P(H|D) \cdot P(H)}{\int_H P(H'|D)P(H')dH'} = \frac{P(D \cdot H)}{\int_H P(D \cdot H')dH'} \quad (1)$$

В классической интерпретации H и D просто рассматриваются как наборы результатов. А байесовская интерпретация явно рассматривает H как гипотезу, такую как параметры нейронной сети, а D как некоторые данные. В классической интерпретации невозможно определить вероятностный

закон для гипотезы H , в то время как Байесовская статистика занимается установлением этого закона. На языке Байесовской статистики $P(D|H)$ называется *правдоподобием*, $P(H)$ *априори*, $P(D)$ *свидетельством* и $P(H|D)$ *апостериори*. Обозначим $P(D|H) \cdot P(H) = P(D, H)$ совместную вероятность D и H .

Эта интерпретация, которую можно понимать как обучение на основе данных D , означает, что байесовская парадигма не просто предлагает надежный подход для количественной оценки неопределенности в моделях глубокого обучения. Он также дает математическую основу для понимания многих методов регуляризации и стратегий обучения, которые уже используются в классическом глубоком обучении.

Байесовская нейронная сеть определяется в литературе несколько иначе, но общее определение состоит в том, что байесовская нейронная сеть – это стохастическая искусственная нейронная сеть, обученная с использованием байесовского вывода.

Цель искусственных нейронных сетей (ИНС) – представить произвольную функцию $y = NN(x)$. Традиционные ИНС (например, сети с прямой связью, рекуррентные сети, разветвленные сети и т. д.) строятся с использованием последовательности одного входного уровня, нескольких скрытых слоев и одного выходного уровня. Мы обозначаем входные переменные как x , а выходные переменные (прогнозы) как y . В сетях с прямой связью, простейшей архитектуре, каждый уровень l представлен как линейное преобразование априори, за которым следует нелинейная операция nl (также известная как функция активации):

$$\begin{aligned}
 x &= l_0, \\
 l_i &= nl_i(W_i l_{i-1} + b_i), \quad \forall i = [1, n] \\
 l_n &= y
 \end{aligned}
 \tag{2}$$

Существуют также более сложные архитектуры (например, сети с несколькими входами, выходами, экзотическими функциями активации, повторяющимися архитектурами и т.д.). Это означает, что данная архитектура ИНС представляет собой набор функций, изоморфных набору возможных коэффициентов θ , которые представляют все веса W и смещения b сети. Глубокое обучение – это процесс регрессии параметров θ для некоторых обучающих данных D , обычно серии входных данных x и их соответствующих меток y .




Рисунок 1. - Нейронные сети точечной оценки (а), в которых изучается только набор весов, нейронные сети стохастической активации (б), где изучается только набор весов вместе с распределением вероятностей для активации, и нейронные стохастические коэффициенты сети (с), где изучается распределение вероятностей по весам.

Стандартный подход состоит в том, чтобы аппроксимировать точечную оценку минимальной стоимости $\hat{\theta}$ с использованием алгоритма обратного распространения, отбрасывая все другие возможные параметризации.

Функция стоимости часто определяется как логарифмическая вероятность обучающего набора, иногда со сроком регуляризации, чтобы снизить параметризацию. Со статистической точки зрения, это можно рассматривать как оценку максимального правдоподобия (MLE), соответственно, оценку максимального апостериори (MAP) при использовании регуляризации.

Подход точечной оценки относительно прост (с современными алгоритмами и программными пакетами), но имеет тенденцию к недостатку объяснимости и может непредвиденным и чрезмерно самоуверенным образом обобщать точки данных распределения вне обучения. Это свойство и неспособность ИНС ответить «я не знаю» является проблематичным в тех областях, где их прогнозы имеют решающее значение, таких как торговля, автономное вождение или медицинские приложения.

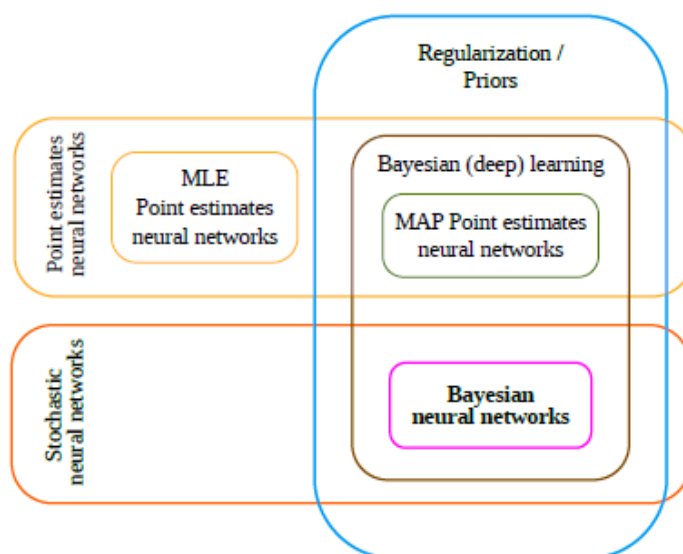


Рисунок 2. - Классификация нейронных сетей со статистической точки зрения

Мы различаем нейронные сети точечной оценки, в которых изучается один экземпляр параметров, и стохастические нейронные сети, в которых изучается распределение по параметрам. Модели точечных оценок без

регуляризации, которые подразумевают неявную однородную апостериорную оценку, изучаются с использованием оценки максимального правдоподобия, тогда как модели точечных оценок с регуляризацией изучаются с помощью максимальной апостериорной оценки. Байесовские нейронные сети – это стохастические нейронные сети с априорными функциями.

Стохастические нейронные сети – это тип ИНС, построенный путем введения в сеть стохастических компонентов (путем предоставления стохастической активации сети: рис. 1b или стохастических весов: рис. 1c) для моделирования нескольких возможных моделей θ с их соответствующим распределением вероятностей $p(\theta)$, когда вместо обучения одной единственной модели обучается набор моделей, а их прогнозы агрегируются.

Основная цель использования архитектуры стохастической нейронной сети - получить лучшее представление о неопределенности, связанной с лежащими в основе процессами. Это достигается путем сравнения прогнозов параметризации θ множественной выборки модели. Если разные модели согласуются, неопределенность низкая. Если они не согласуются, то неопределенность высокая. Этот процесс можно резюмировать следующим образом:

$$\begin{aligned}\theta &\sim p(\theta), \\ y &= NN_{\theta}(x) + \varepsilon,\end{aligned}$$

где ε , представляет собой случайный шум, чтобы учесть тот факт, что функция NN является всего лишь приближением.

Байесовская нейронная сеть (BNN) может быть определена как любая стохастическая искусственная нейронная сеть, только обученная с использованием байесовского вывода. Первым шагом для разработки BNN является выбор архитектуры глубокой нейронной сети, то есть

функциональной модели. Затем необходимо выбрать стохастическую модель, то есть априорное распределение по возможной параметризации модели $p(\theta)$ и априорную уверенность в предсказательной способности модели $p(y|x, \theta)$. Параметризацию модели можно рассматривать как гипотезу H , а обучающий набор – как данные D . Далее мы будем обозначать параметр модели как θ и использовать D для обозначения обучающего набора, D_x для обозначения обучающих функций и, $D(y)$ для обозначения обучающих меток. Это сделано для того, чтобы различать обучающие данные и любую пару *ввода/вывода* (x, y) . Применяя теорему Байеса и обеспечивая независимость между параметрами модели и входными данными, байесовскую апостериорную функцию вероятности можно записать как:

$$p(\theta|D) = \frac{p(D_y|D_x, \theta) \cdot p(\theta)}{\int_{\theta} p(D_y|D_x, \theta') \cdot p(\theta') d\theta'} \propto p(D_y|D_x, \theta) \cdot p(\theta). \quad (3)$$

Вычисление этого распределения и, тем более, выборка из него с использованием стандартных методов, обычно является трудноразрешимой проблемой, особенно с учетом того, что вычислить нормирующий множитель (evidence) $\int_{\theta} p(D_y|D_x, \theta') \cdot p(\theta') d\theta'$ сложно. Для решения этой проблемы возможны два подхода.

Первый - использовать алгоритм Монте-Карло цепи Маркова, который позволяет напрямую брать апостериорную выборку, но требует кэширования коллекции выборок Θ . Второй - использовать подход вариационного вывода, который изучает вариационное распределение $q_{\phi}(\theta)$ для аппроксимации точного апостериорного распределения. Оба эти метода обходят вычисление знаменателя уравнения (3), что объясняет,

почему апостериорное значение часто приводится к константе масштабирования,

Учитывая байесовское апостериорное или его вариационное приближение, становится возможным вычислить предельное распределение вероятностей выходных данных при определенных входных данных, которые точно определяют неопределенность модели:

$$p(y|x, D) = \int_{\Theta} p(y|x, \theta') \cdot p(\theta'|D) d\theta'$$

На практике, распределение $p(y|x, D)$ выбирается косвенно с использованием уравнения 3. θ выбирается из вариационного распределения $q_{\phi}(\theta)$ или равномерно в Θ . Окончательный прогноз резюмируется несколькими статистическими данными, вычисленными с использованием подхода Монте-Карло.

Подводя итог предсказаниям BNN, используемым для выполнения регрессии, обычной процедурой является выполнение усреднения модели:

$$\hat{y} = \frac{1}{|\Theta|} \cdot \sum_{\theta_i \in \Theta} NN_{\theta_i}(x)$$

Для количественной оценки неопределенности ковариационная матрица может быть вычислена следующим образом:

$$\sum_{y|x, D} = \frac{1}{|\Theta| - 1} \cdot \sum_{\theta_i \in \Theta} (NN_{\theta_i}(x) - \hat{y})(NN_{\theta_i}(x) - \hat{y})^T$$

При выполнении классификации прогноз средней модели даст относительную вероятность каждого класса, которую в данном случае можно рассматривать как меру неопределенности:

$$\hat{\mathbf{p}} = \frac{1}{|\Theta|} \cdot \sum_{\theta_i \in \Theta} NN_{\theta_i}(\mathbf{x}).$$

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Jimmy Lei Ba, Jamie Ryan Kiros, and Geoffrey E Hinton. Layer normalization. CoRR, arXiv:1607.06450, 2016. In NIPS 2016 Deep Learning Symposium.
2. Rémi Bardenet, Arnaud Doucet, and Chris Holmes. On Markov Chain Monte Carlo methods for tall data. J. Mach. Learn. Res., 18(1):1515–1557, January 2017. ISSN 1532–4435.
3. Yarin Gal, Riashat Islam, and Zoubin Ghahramani. Deep Bayesian active learning with image data. In Proceedings of the 34th International Conference on Machine Learning - Volume 70, ICML'17, page 1183–1192, 2017.
4. Zoubin Ghahramani and Matthew J. Beal. Propagation algorithms for variational Bayesian learning. In T. K. Leen, T. G. Dietterich, and V. Tresp, editors, Advances in Neural Information Processing Systems 13, pages 507–513. MIT Press, 2001.

LXD ЖӘНЕ ОНЫ ОПЕРАЦИЯЛЫҚ ЖҮЙЕНІ ВИРТУАЛДАНДЫРУДА ҚОЛДАНУ ЕРЕКШЕЛІКТЕРІ

Тишбаева А.Д., Кусепова Л.Т., Қайупов Е.К., Қалдарова М.Ж., Назырова А.Е.

Аннотация. Бұл мақалада LXC, LXD, Docker және Podman технологияларының архитектурасы мен мүмкіндіктерін талдау Linux ортасында контейнерлеудің заманауи тәсілдерін зерттеудегі маңызды қадам болып табылады. Бұл технологиялардың әрқайсысында оқшаулау деңгейлерін, ресурстарды басқару әдістерін және контейнерлерді орналастыру мен басқару тәсілдерін қоса алғанда, бірегей мүмкіндіктер бар. Жұмыс қарастырылатын платформалардың әрқайсысының артықшылықтары мен шектеулерін анықтау үшін оларды кейіннен салыстырмалы талдау және әртүрлі АТ сценарийлерінде пайдалану үшін жүргізіледі.

LXD (Linux Containers Daemon) – бір хостта операциялық жүйелердің оқшауланған даналарын іске қосуға арналған Linux операциялық жүйелеріне арналған заманауи контейнерлеу ішкі жүйесі. Толық физикалық жүйелерді эмуляциялайтын дәстүрлі виртуалды машиналардан айырмашылығы, LXD контейнерлері негізгі операциялық жүйенің ядросын ортақ пайдаланады, нәтижесінде өнімділік жоғарылайды және ресурс шығыны азаяды.

Linux ядросының топтары мен аттар кеңістігі технологияларына негізделген LXD операциялық жүйе деңгейінде контейнерлерді орналастыру және басқару үшін тиімді шешім ұсынады. Бұл технология бұлтты есептеулерді, бағдарламалық жасақтаманы әзірлеуді, тестілеуді және масштабталатын орталарды құруды қоса алғанда, әртүрлі салаларда кең қолдануды тапты.

LXD 2014 жылы шығарылды, сол кезде Docker кеңінен қолданылып, іс жүзінде дәлелденді. Docker сияқты, LXD және LXC технологиясын негіз ретінде пайдаланады, бірақ олардың қолданбалары айтарлықтай ерекшеленеді. Егер Docker қолданбаларды контейнерлерде іске қосуға арналған болса, онда LXD толыққанды операциялық жүйелерді жасауға бағытталған. Бұл LXD-ті дәстүрлі мағынада контейнерлер жасау үшін ғана емес, сонымен қатар жеңіл виртуалды машиналарды орналастыру үшін де пайдалануға мүмкіндік береді. «Lightvisor» термині LXD контейнерлерінің жеңілдігі мен жоғары өнімділігін баса көрсететін Canonical басылымдарында жиі жазылып жүрді. Canonical мәліметтері бойынша, LXD контейнерлері дәстүрлі KVM негізіндегі виртуалды машиналарға қарағанда 10 есе жылдам жұмыс істей алады. LXD ағымдағы нарық талаптарын ескере отырып

әзірленген динамикалық ресурстарды басқару механизмін, кеңейтілген контейнерлік көшіру мүмкіндіктерін, соның ішінде нақты уақыт режимін және жақсартылған қауіпсіздік жүйесін қамтиды. Docker-пен салыстырғанда, LXD контейнерлерді қайта конфигурациялау үшін айтарлықтай көбірек опцияларды ұсынады. Сонымен қатар, LXD ашық API-ді қолдайды және әртүрлі программалау тілдеріне арналған клиенттері бар, сонымен қатар Nova клиенті арқылы контейнерлерді тиімді басқаруға мүмкіндік беретін OpenStack-пен біріктіруге арналған плагин бар.

Docker – контейнерлерде қолданбаларды әзірлеуге және орналастыруға бағытталған ең танымал контейнерлеу технологияларының бірі. Docker қолданбаларды Docker файлдарының көмегімен Docker кескіндеріне буып, содан кейін оларды Docker Engine жұмыс істейтін кез келген хостқа орналастыруды жеңілдетеді.

Docker – контейнерлердің өмірлік циклін құру және басқару, соның ішінде олардың денсаулығын бақылау үшін құралдардың толық жинағын ұсынатын ашық бастапқы контейнерлеу платформасы [1]. Докердің басты артықшылығы оның контейнерлік қолданбаларды орналастыруды, тестілеуді және масштабтауды оңтайландыру мүмкіндігі болып табылады, бұл оны микросервис архитектураларында пайдалану үшін әсіресе қолайлы етеді. Бұл платформа қолданбаларды кеңейтуге болатын жеке, оқшауланған қызметтерге бөлуді жеңілдетеді, қолданбаларды әзірлеу мен орналастыруда икемділікті қамтамасыз етеді.

Docker Docker Hub сияқты жалпыға ортақ тізілім серверлері арқылы ортақ бейнелерді немесе кітапханаларды жасауға мүмкіндік беретін қабатты файлдық жүйені (Unionfs) пайдаланады. Бұл қолданбаларды немесе қызметтер жиынын әртүрлі орталар арқылы тасымалдауды жеңілдетеді, себебі әрбір контейнер данасы қолданбаны немесе микросервисті Linux немесе Windows болсын, кез келген серверде іске қосу үшін барлық қажетті тәуелділіктермен бірге инкапсуляциялайды. Мысалы, Apache TomCat қолданба сервері мен MySQL дерекқорын қажет ететін қолданба үшін әзірлеуші осы екі элементпен негізгі кескінді құру үшін пәрмендер тізбегінен тұратын Dockerfile жасай алады. Бұл кескінді кейін басқа компьютерлерге таратуға болады.

Техникалық тұрғыдан алғанда, Docker жеңіл және бастапқыда Linux жүйелеріндегі Linux контейнерлерінің (LXC) үстіне салынған. Дегенмен, кейіннен Docker Docker қозғалтқышына біріктірілген libcontainer деп аталатын өзінің жұмыс уақытын жасады. Бұл құрылым тиімді контейнерлеуді қосу үшін аттар кеңістігі және топтар сияқты ядро мүмкіндіктерімен өзара әрекеттеседі. Docker қажет болған жағдайда QEMU

эмуляторын пайдаланады, ал Windows жүйесінде Hyper-V және WSL2 технологияларын пайдаланады. Әрбір контейнерде бастапқы ОЖ іске қосатын, содан кейін басқа процестерді іске қоса алатын LXC-тен айырмашылығы, Docker Docker кескінінде көрсетілген қолданбаларды іске қосу үшін Docker қозғалтқышын пайдаланып ОЖ ортасын қамтамасыз етеді.

Docker архитектурасының негізінде контейнерлерді жасауға, басқаруға және іске қосуға мүмкіндік беретін бірнеше жоғары деңгейлі компоненттер бар. Бұл Docker CLI, Docker демоны және оның REST API интерфейсі, олар бірге Docker-ті кеңінен қабылдауға үлес қосты. Docker CLI пайдаланушылар үшін Docker-пен өзара әрекеттесу және командаларды жіберу үшін негізгі интерфейс ретінде қызмет етеді, олар REST API арқылы Docker демонына сұрауларға аударылады. Содан кейін Docker демоны кескіндер мен контейнерлер сияқты Docker нысандарында алу немесе іске қосу сияқты қажетті басқару әрекеттерін орындайды.

Бұл әрекеттерді және контейнерлерді ең төменгі деңгейде орындауды қолдайтын екі құрамдас Containerd және runC болып табылады. Containerd жоғары деңгейлі орындалу ортасын қамтамасыз етеді, хост жүйесіндегі барлық контейнерлердің өмірлік циклін басқарады және әртүрлі ОЖ ядроларына (Linux, Windows немесе Solar) шақыруларды қысқартады. runC компоненті контейнерді іске қосу үшін пайдаланылатын ең төменгі деңгей құрамдас бөлігі болып табылады; мысалы, ол контейнерлерді жасау және іске қосу үшін жергілікті Linux функцияларын пайдаланады және runC libcontainer қамтиды. Бұл төмен деңгейлі құрамдас бөліктер, Containerd және runC, контейнерлік платформалар арасындағы өзара әрекеттесуді алға жылжытуға және қосуға бағытталған Open Container Initiative спецификацияларына сәйкес келеді [2, 3]. Осылайша, Kubernetes оркестрінің құралы жоғары деңгейлі Docker Containerd орындалу уақытын немесе Kubernetes үшін құрастырылған CRI-O құрылымын пайдалана алады [4, 5].

LXC (Linux контейнерлері) жалпы операциялық жүйе ядросын ортақ пайдаланатын контейнерлер деп аталатын оқшауланған орталарды жасау үшін Linux ядросын пайдаланады. Бұл ресурстарды пайдалануды оңтайландыра отырып, бір хостта бірнеше оқшауланған процестерді іске қосуға мүмкіндік береді. LXD (Linux Containers Daemon) – бұл LXC-ден жоғары деңгейдегі абстракция, ол қолданбалы контейнерлер үшін ғана емес, сонымен қатар толыққанды виртуалды машиналар үшін де мүмкіндік береді. Ол ресурстарды басқару, контейнерлерді тасымалдау және басқа серверді басқару құралдарымен біріктіру мүмкіндіктерін қосады. Linux LXC – бір хостта толығымен оқшауланған бірнеше виртуалды ортаны (VE) немесе Linux контейнерлерін жасауға және іске қосуға мүмкіндік беретін

операциялық жүйе деңгейіндегі виртуалдандыру технологиясы [6]. Бұл контейнерлерді үш жолмен пайдалануға болады: виртуалды ортада арнайы қолданбаларды немесе микросервистерді іске қосу үшін құм жәшік ретінде, қолданба контейнерлері ретінде немесе бүкіл операциялық жүйені жүйелік контейнерлер ретінде виртуализациялау үшін. LXC өз ядросын контейнерлермен бөлісу және CPU, жад, диск және контейнерлер арасындағы желіні шектеу үшін контейнерлерді және жергілікті Linux функцияларын, топтарын оқшаулау үшін аттар кеңістігі механизмін пайдаланады. Бұл тәсіл қосымша ядро жүктеген үстеме шығындарды болдырмайды және жоғары тиімділік пен жақсы өнімділікті қамтамасыз ететін ресурстарды аз тұтынады [7].

Жүйелік контейнерлер үшін LXC бір контейнердегі бірнеше қолданбалы процестерді қолдайтын оқшауланған виртуалды органы құруға жалғыз іске қосу процесіне мүмкіндік беретін Docker-тен ерекшеленеді. LXC Docker және LXD сияқты контейнерлерді басқару құралдарымен біріктірілуі мүмкін, бұл сізге бірнеше күрделі виртуалды орталарды оңай жасауға, олардың қолжетімділігін арттыруға мүмкіндік береді.

LXD LXC кеңейтімі болып табылады және оны LXC бағдарламалық кітапханасымен (liblxc) байланысу үшін REST API пайдалану арқылы Docker сияқты заманауи контейнерге және виртуалды машинаны басқару құралына түрлендіруді, қауіпсіздік пен оқшаулауды жақсарту сияқты LXC мүмкіндіктерін кеңейтуді мақсат етеді (мысалы. рұқсат етілмеген контейнерлерді анықтау), контейнерлердің тірі миграциясы және әрбір контейнер пайдаланатын ресурстарды шектеу [8]. LXD сонымен қатар кескінге негізделген және әртүрлі серверлер мен желі түрлерін, сондай-ақ ноутбуктерден бұлттағы тірек серверлеріне дейінгі аппараттық құралдарды қолдау арқылы икемділік пен масштабтылықты қамтамасыз ететін әртүрлі Linux дистрибутивтерінен кескіндердің кең ауқымын ұсынады.

LXD платформасы контейнерлерді жасауды және басқаруды жеңілдетеді, бұл әр контейнерді және оның параметрлерін, соның ішінде ресурсты жабу, суретке түсіру және пәрмен жолы құралы, REST API арқылы хосттар арасында контейнерлерді тасымалдауды қоса алғанда, үлкен бақылауға мүмкіндік беретін контейнерді басқарудың қосымша деңгейін ұсынады. , немесе үшінші тарап құралдары [9, 10].

Podman – ұқсас контейнерлерді басқару мүмкіндіктерін қамтамасыз ететін, бірақ демонды қажет етпейтін және қосымша қауіпсіздік мүмкіндіктері бар Docker балама. Podman Dockerfile үйлесімділігін сақтай отырып, пәрмен жолынан контейнерлерді іске қосуға және басқаруға мүмкіндік береді.

LXC, LXD мен Docker, Podman контейнерлері салыстырылып, кестеде көрсетіледі.

Кесте 1 LXC, LXD мен Docker, Podman контейнерлерін салыстыру

Сипаттама	LXC	LXD	Docker	Podman
Негізі	LXC пайдаланады	LXC пайдаланады	Жеке технология	Жеке технология
Контейнерлер типі	Шектелген процестер	Шектелген операциялық жүйелер	Шектелген қосымшалар	Шектелген қосымшалар
Пайдаланылуы	Төмен деңгейлі контейнерлер	Жоғары деңгейлі контейнерлер	Қосымшалар мен микросервистер	Қосымшалар мен микросервистер
Ресурстарды басқару	Шектелген	Кеңейтілген	Шектелген	Шектелген
Интеграция	Шектелген	Бар	Бар	Бар
Төзімділік	Шектелген	Жоғары	Орта	Орта
Контейнерлердің миграциялануы	Шектелген	Кеңейтілген	Шектелген	Шектелген
Контейнердің ішінде іске қосылуы	Иә	Иә	Иә	Иә
API	Шектелген	Ашық	Ашық	Ашық
Dockerfile қолдауы	Жоқ	Жоқ	Иә	Иә

LXC жиі операциялық жүйе деңгейінде әзірлеу және тестілеу үшін қолайлы оқшауланған орталарды жасау үшін пайдаланылады. LXD жеңіл виртуалды машиналарды орналастыруға және үлкен жүйелердегі ресурстарды басқаруға бағытталған. Docker және Podman DevOps және микросервис архитектураларында қолданбаларды контейнерлеу үшін кеңінен қолданылады.

LXD OpenStack-пен біріктірілген және басқаруды автоматтандыру үшін API ұсынады. Docker және Podman Docker кескіндерін ортақ пайдалану үшін Docker Hub қолдауын қамтамасыз етеді және үздіксіз интеграция мен қолданбаларды жеткізу үшін CI/CD конвейерлерімен жасалған.

Төменде осы технологиялардың архитектуралық ерекшеліктері қарастырылады.

Абстракциялық деңгей бойынша LXC процестер мен ресурстарды оқшаулау үшін namespaces және cgroups пайдалана отырып, Linux ядросы деңгейінде контейнерлерге төмен деңгейлі қатынасты қамтамасыз етеді. LXC контейнерлері ресурстарды тереңірек басқаруды және түсінуді талап ететін негізгі жүйенің өзегіне тікелей қол жеткізе алады.

LXD – LXC-ден жоғары деңгейлі абстракция болып табылады, тасымалдау және бейнелер сияқты кеңейтілген функционалдылықты қамтамасыз ететін демон арқылы контейнерді басқаруды қамтамасыз етеді. LXD контейнерлерді басқаруға арналған RESTful API интерфейсі қолдайды, автоматтандыруды және басқа жүйелермен интеграцияны жеңілдетеді.

Docker клиент-сервер архитектурасын пайдаланады, мұнда Docker CLI контейнерлерді басқаруға жауапты Docker демонымен байланысады. Docker кескінді және желіні оңай басқаруды қамтамасыз ететін контейнерлерде қолданбаларды орналастыруға және басқаруға бағытталған.

Podman контейнерлерді қалыпты процестер ретінде басқару үшін libpod көмегімен Docker демонын қажет етпей, контейнерлерді түбірсіз режимде іске қосуға мүмкіндік береді. Podman ұқсас пайдаланушы тәжірибесін және маңызды өзгерістерсіз осы құралдар арасында жылжу мүмкіндігін қамтамасыз ететін Docker CLI-мен үйлесімді.

LXC, LXD, Docker және Podman архитектурасындағы бұл айырмашылықтар олардың әр түрлі контейнерлік және қолданбалы басқару сценарийлеріндегі арнайы артықшылықтары мен қолданылуын анықтайды.

Ubuntu 20.04 жүйесінде LXD орнату және конфигурациялау үшін мына қадамдарды орындауға болады:

Репозиторийлерді жаңарту:

Пакет тізімі жаңартылғанына көз жеткізу керек: `sudo apt update`

LXD пакетін ресми Ubuntu репозиторийлерінен орнату керек: `sudo apt install lxd`.

Орнатқаннан кейін LXD инициализациясы қажет. Бұл негізгі конфигурацияны орнату және бастапқы параметрлерді жасау: `sudo lxd init`.

LXD орнату үшін нұсқауларды орындау керек. Желі интерфейстері, сақтау және басқа параметрлер туралы сұрақтар қойылады.

LXD баптандыру процесі кезінде контейнерлер мен кескіндерді сақтауға арналған серверді таңдау сұралады. Сіз ZFS, Btrfs таңдауға немесе ext4 файлдық жүйесіндегі каталогтарды пайдалануға болады. LXD контейнерлер үшін желі көпірін конфигурациялауды ұсынады. Ортаға байланысты әдепкі желі көпірін пайдалануға немесе жаңасын жасауға болады.

LXD жүйесіндегі ресурстарды басқару оқшауланған орталардың тиімділігі мен тұрақтылығын қамтамасыз етуде маңызды рөл атқарады. Біріншіден, lxc конфигурация жиыны `lxc config set <container_name> limits.memory 512MB` командасымен шектеу орнату арқылы контейнерге қолжетімді жедел жады көлемін оңай шектей алады. Екінші маңызды аспект - болжанатын және дәйекті өнімділікті қамтамасыз ететін lxc конфигурация жиыны `lxc config set <container_name> limits.cpu 1,3` командасын пайдалану арқылы қол жеткізілетін арнайы процессордың ядроларымен контейнерді байланыстыру мүмкіндігі. Үшінші команда, `lxc config set <container_name> limits.cpu.allowance 10%` контейнердің басқа тапсырмаларға үстемдік етуіне жол бермеу үшін пайдалы процессорды пайдалану пайызын басқаруға мүмкіндік береді. Дискілік кеңістікті басқару үшін lxc конфигурация жинағы `lxc config set <container_name> limits.disk <pool_name> 10GB` көмегімен қордың тиімді бөлінуін қамтамасыз ететін ең үлкен контейнер түбірлік бөлімінің өлшемін орнатуға болады. Бұған қоса, LXD желі ресурстарын басқару мүмкіндігін береді, дегенмен арнайы параметрлер таңдалған желі конфигурациясына байланысты. Бұл мүмкіндіктер контейнердің шамадан тыс ресурстарды тұтынуын болдырмауға және хост жүйесіндегі басқа қолданбалардың тұрақты жұмысын қамтамасыз етуге көмектеседі.

LXD-де снапшоттармен жұмыс істеу – контейнерлердің күйін басқарудың қуатты құралы. Біріншіден, снапшоттар контейнердің ағымдағы күйі үшін сақтау нүктелерін жасауды жеңілдетеді, ол `lxc snapshot <container_name> <snapshot_name>` командасымен орындалады. Контейнердің алдыңғы күйіне оралу қажет болса, сурет жасалғанға дейін оның күйін қалпына келтіруді қамтамасыз ететін `lxc restore <container_name> <snapshot_name>` командасын пайдалануға болады. Сондай-ақ, `apt-get install criu` командасымен орнатуға болатын CRIU утилитасын пайдаланып, контейнердегі барлық процестердің ағымдағы күйін сақтайтын күйі бар суретті жасауға болады. Снапшоттар тізімін және олардың күйлерін көру үшін контейнер күйі мен ресурстары туралы пайдалы ақпаратты қамтамасыз ететін `lxc info <container_name>` командасы пайдаланылады. LXD ішіндегі снапшотпен жұмыс істеу контейнерлерді басқару кезінде икемділік

пен қауіпсіздікті қамтамасыз етеді, бұл оларды қолданбаларды қолдану және тестілеу үшін тиімді етеді.

ҚОРЫТЫНДЫ

Docker, LXC, LXD және Podman архитектуралары мен мүмкіндіктерін талдау бұл технологиялардың әрқайсысының контейнерлендіру және виртуализациялауда өзіндік бірегей артықшылықтары мен қосымшалары бар екенін көрсетеді. Docker микросервис қосымшаларын масштабтауға қолайлы кең таралған және қуатты экожүйелік тәсілімен ерекшеленеді. LXC өнімділігі жоғары және ең аз шығыны бар жеңіл ОС деңгейіндегі виртуализация шешімін ұсынады. LXD, LXC кеңейтімі жақсартылған басқару және қауіпсіздік мүмкіндіктерін қосады, бұл оны кәсіпорын үшін тартымды етеді. Podman, өз кезегінде, демонды және артықшылықты қолжетімділікті қажет етпестен контейнерлерді басқару құралдарына тікелей интеграциясы бар Docker-ке балама ұсынады.

Бұл технологиялар арасындағы таңдау жобаның ауқымдылығы мен басқаруынан қауіпсіздік пен бар инфрақұрылыммен интеграцияға дейінгі нақты қажеттіліктеріне байланысты. Олардың мүмкіндіктерін түсіну әзірлеушілер мен әкімшілерге контейнерлік қолданбаларды орналастыру және басқару үшін дұрыс құралды таңдау кезінде негізделген шешім қабылдауға көмектеседі.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Docker: Accelerated, Containerization. Available online: <http://www.docker.com/> (accessed on 10 June 2023).
2. Containerd—An Industry-Standard Container Runtime with an Emphasis on Simplicity, Robustness and Portability. Available online: <https://containerd.io> (accessed on 20 January 2024).
3. Open Container Initiative. Available online: <https://opencontainers.org> (accessed on 20 January 2024).
4. Docker vs. Containerd vs. CRI-O: An In-Depth Comparison. Available online: <https://phoenixnap.com/kb/docker-vs-containerd-vs-cri-o> (accessed on 20 January 2024).
5. Lightweight Container Runtime for Kubernetes. Available online: <https://cri-o.io> (accessed on 20 January 2024).
6. Linux Containers. Available online: <https://linuxcontainers.org/> (accessed on 20 January 2024).
7. Singh, S.; Singh, N. Containers & Docker: Emerging roles & future of Cloud technology. In Proceedings of the 2016 2nd International Conference on

Applied and Theoretical Computing and Communication Technology, iCATccT 2016, Bengaluru, India, 21–23 July 2016; pp. 804–807. [Google Scholar] [CrossRef]

8. Run System Containers with LXD. Available online: <https://canonical.com/lxd> (accessed on 22 March 2024).

9. Jain, H. LXC and LXD: Explaining Linux Containers, 2 June 2016. Available online: www.sumologic.com/blog/lxc-lxd-linux-containers/ (accessed on 20 January 2024).

10. Andrei, A. What Is the Difference between Docker, LXC, and LXD Containers? 22 August 2022. Available online: <https://kodekloud.com/blog/what-is-the-difference-between-docker-lxc-and-lxd-containers/> (accessed on 20 January 2024).

МАППИНГ БОЛЬШИХ ДАННЫХ: СОВРЕМЕННЫЕ ПОДХОДЫ И МЕТОДЫ В 2024 ГОДУ

Ж.Т.Абдуллаева, Д.Е.Жеңіс

Международный университет Астана

Аннотация. С ростом объёмов данных и их разнообразия в последние годы, маппинг больших данных стал критически важным для эффективной обработки и анализа информации. В этой статье рассматриваются современные подходы и методы маппинга больших данных, включая алгоритмы, инструменты и архитектурные решения, актуальные для 2024 года. Приводятся примеры использования в различных отраслях, обсуждаются проблемы и предлагаются возможные направления для будущих исследований.

Ключевые слова. Маппинг больших данных, Большие данные, Алгоритмы, Инструменты, Обработка данных, 2024

ВВЕДЕНИЕ

Современные организации сталкиваются с огромными объёмами данных, которые необходимо эффективно обрабатывать и анализировать. Маппинг больших данных представляет собой процесс преобразования необработанных данных в структурированный вид, подходящий для анализа. Это включает в себя экстракцию, трансформацию и загрузку данных (ETL), а также применение алгоритмов машинного обучения и других методов для выявления скрытых закономерностей. В данной статье рассматриваются текущие подходы и методы маппинга больших данных, а также их применение в 2024 году.

Текущие подходы к маппингу больших данных
ETL-процессы.

Процесс ETL (Extract, Transform, Load) остаётся основой маппинга больших данных. Современные инструменты ETL, такие как Apache Nifi, Talend и Apache Beam, позволяют автоматизировать и оптимизировать этот процесс. Пример кода для ETL-процесса с использованием Apache Beam

```
import apache_beam as beam
from apache_beam.options.pipeline_options import PipelineOptions

def run():
    options = PipelineOptions()
```

```
with beam.Pipeline(options=options) as p:  
    (p  
     | 'ReadData' >> beam.io.ReadFromText('input_data.txt')  
     | 'TransformData' >> beam.Map(lambda x: x.upper())  
     | 'WriteData' >> beam.io.WriteToText('output_data.txt'))  
  
if __name__ == '__main__':  
    run()
```

АЛГОРИТМЫ И МЕТОДЫ

Современные алгоритмы машинного обучения и искусственного интеллекта играют важную роль в маппинге больших данных. Методы кластеризации, классификации и регрессии позволяют извлекать ценные информации из больших объемов данных. В 2024 году особое внимание уделяется гибридным моделям и методам глубокого обучения.

Инструменты и платформы.

Существует множество инструментов и платформ для маппинга больших данных. Среди них Apache Hadoop, Apache Spark, Google BigQuery и другие. Эти инструменты позволяют масштабировать обработку данных и выполнять сложные вычисления в распределенной среде.

Архитектурные решения

1. Lambda-архитектура.

Lambda-архитектура сочетает в себе обработку потоков данных в реальном времени и пакетную обработку для обеспечения высокой производительности и надёжности.

2. Карра-архитектура.

Карра-архитектура фокусируется исключительно на потоковой обработке данных, упрощая архитектуру и снижая задержки.

3. Lambda-архитектура vs Карра-архитектура.

Одним из самых больших недостатков архитектуры Lambda является то, что ее реализация может быть сложной и дорогой. Это связано с тем, что для этого требуется внедрение и обслуживание двух отдельных конвейеров обработки: один для пакетной обработки, а другой для обработки в реальном времени/потоковой обработки. Эта дополнительная сложность и стоимость могут стать серьезным препятствием для организаций, желающих внедрить эту архитектуру. Кроме того, архитектуру Lambda также может быть сложно масштабировать по мере увеличения объема данных. Это связано с тем, что уровень пакетной обработки обычно труднее масштабировать, чем уровень обработки в реальном времени/потоковой обработке. В результате организации, имеющие дело с большими объемами

данных, могут обнаружить, что архитектура Lambda не является масштабируемым решением для их нужд.

В целом архитектура Lambda — сложное и дорогое решение, которое может подойти не всем организациям. Организации, которые ищут более простое и экономически эффективное решение, могут рассмотреть другие архитектуры обработки данных, например архитектуру Карра. Архитектура Карра приобрела популярность в последние годы, поскольку она проще, масштабируемее и легче в обслуживании, чем архитектура Lambda.

Примеры использования

Маппинг больших данных используют финансовые компании для анализа транзакций, обнаружения мошенничества и прогнозирования рыночных трендов. А также, в здравоохранении, помогает в анализе медицинских записей, исследовании геномных данных и прогнозировании эпидемий.

Проблемы и вызовы: с увеличением объёмов данных, поддержание масштабируемости становится всё более сложной задачей. А также, обработка больших данных требует соблюдения строгих мер по обеспечению конфиденциальности и безопасности данных.

Будущие направления исследований

- Интеграция квантовых вычислений.
- Квантовые вычисления обещают революционизировать обработку больших данных, предлагая значительное увеличение производительности.
- Развитие искусственного интеллекта.
- Развитие методов искусственного интеллекта продолжит улучшать возможности маппинга данных, позволяя извлекать ещё более глубокие информации.

ЗАКЛЮЧЕНИЕ

Маппинг больших данных остаётся ключевым элементом в обработке и анализе данных. Современные подходы и методы, описанные в этой статье, показывают значительный прогресс в этой области и открывают новые возможности для будущих исследований и приложений.

СПИСОК ЛИТЕРАТУРЫ.

1. Dean, J., & Ghemawat, S. (2008). MapReduce: Simplified Data Processing on Large Clusters. *Communications of the ACM*.
2. Zaharia, M., Chowdhury, M., Franklin, M. J., Shenker, S., & Stoica, I. (2010). Spark: Cluster Computing with Working Sets. *HotCloud*.
3. <https://ru.wikipedia.org/wiki/Маппирование>

4. The DTO Pattern (Data Transfer Object) | Baeldung [Электронный ресурс] – Режим доступа: <https://www.baeldung.com/java-dtopattern>.

5. Data Mapping: что такое маппинг данных, лучшие техники и инструменты – Mad Data [Электронный ресурс]. – Режим доступа: <https://maddata.agency/blog/data-mapping-luchshie-tekhniki-i-instrumenty>.

МЕХАНИЗМ ОБЪЕДИНЕНИЯ ДАННЫХ ПРИ МЕТОДЕ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ

Семейхан Ж.Б., Қалдарова М.Ж., Назырова А.Е., Кусепова Л.Т.

Международный университет Астана
kmiraj82@mail.ru

Аннотация. В данной работе представлен обзор современных исследований в области компьютерного зрения и анализа спутниковых изображений. Основное внимание уделено методам извлечения зданий и дорог, распознавания лиц, а также классификации текстур и материалов с использованием глубоких нейронных сетей. Обзор включает ключевые работы, такие как вызов Deep Globe для обработки спутниковых изображений, многофункциональные сети для извлечения зданий, каскадные сверточные сети для распознавания лиц и методы оптимизации моделей глубокого обучения. Рассматриваются как традиционные подходы, так и современные алгоритмы машинного обучения, демонстрирующие высокую эффективность и точность. Исследования показывают значительный прогресс в разработке эффективных и масштабируемых алгоритмов, открывающих новые возможности для применения в различных областях науки и техники.

Ключевые слова: сегментация изображений, объединение данных, глубокое обучение, СНС (сверточные нейронные сети), дистанционное зондирование, оптимизация моделей

ВВЕДЕНИЕ

Современные технологии дистанционного зондирования и анализа изображений играют важную роль в различных областях науки и техники. С развитием методов глубокого обучения и компьютерного зрения стало возможным существенно повысить точность и эффективность обработки и анализа изображений. Спутниковые и аэрофотоснимки, предоставляющие высокоразрешенные данные, используются для решения широкого спектра задач, включая картографирование, мониторинг окружающей среды, городское планирование и многое другое.

Одной из ключевых задач анализа изображений является автоматическое извлечение объектов, таких как здания и дороги, что критично для создания и обновления географических информационных систем (ГИС). В последние годы методы на основе сверточных нейронных сетей (СНС) продемонстрировали выдающиеся результаты в данной области. Однако, несмотря на успехи, остаются проблемы, связанные с

точностью, скоростью и устойчивостью этих методов к изменению условий съемки и различных помех.

Распознавание лиц и классификация текстур и материалов также являются важными задачами в компьютерном зрении. Распознавание лиц находит применение в системах безопасности, биометрии и развлекательных приложениях. Классификация текстур и материалов важна для автоматизации процессов в промышленности и для анализа различных природных и искусственных объектов.

Цель данного обзора – рассмотреть современные достижения в области анализа спутниковых и аэрофотоснимков, а также методов распознавания лиц и классификации текстур, основанных на глубоких нейронных сетях. Рассматриваются как традиционные подходы, так и новейшие алгоритмы, которые позволили значительно улучшить качество и эффективность решения этих задач.

Литературный обзор

Глубокое обучение в области дистанционного зондирования. Несколько исследований продемонстрировали применение методов глубокого обучения для анализа Земли с помощью спутниковых изображений. Demir и др. [1] и Singh P.P. и др. [7] исследовали использование СНС для определения местоположения дорог и анализа земли с помощью спутниковых изображений, демонстрируя их эффективность в задачах дистанционного зондирования. Аналогичные достижения можно увидеть в работе Li L. и соавторов [2], которые разработали сеть повторного использования множества функций для улучшения извлечения информации о зданиях из изображений дистанционного зондирования. Более того, Mokhtarzade M. [8] использовали искусственные нейронные сети для обнаружения дорог, что указывает на растущую сложность и полезность нейронных сетей в геопространственном анализе.

Исследования в области распознавания лиц значительно улучшились благодаря глубокому обучению. Автор [16] рассказал о важности функций потери данных при распознавании лиц, повышающих производительность нейронных сетей. К числу примечательных разработок относятся работы [3,5], которые использовали каскадные сверточные нейронные сети для надежного распознавания лиц и выравнивания параметров, повышая точность и надежность систем распознавания лиц в различных условиях.

Глубокое обучение также помогло в идентификации и классификации материалов. Авторы [11,13] представили фреймворки для распознавания материалов в неконтролируемых средах с использованием контекстно-зависимых баз данных и функций, основанных на восприятии,

соответственно. Этот сектор расширился до классификации текстур, где ученые [12] представили глубокую сверточную сеть, ограниченную локальностью и разреженностью, для повышения точности классификации текстур. Эффективность сетей глубокого обучения была важнейшей областью исследований, о чем свидетельствуют работы [10], которые проанализировали технологии сокращения и ускорения в СНС. Это имеет решающее значение для внедрения этих технологий в приложениях реального времени, где вычислительные ресурсы и время отклика ограничены. Выводы Исследование показывает значительную тенденцию к использованию глубокого обучения для решения сложных задач обработки изображений в различных областях, включая дистанционное зондирование, распознавание лиц и классификацию материалов. Каждое исследование способствует более широкому пониманию того, как глубокое обучение может быть оптимизировано и применено к конкретным задачам реального мира, подчеркивая адаптивность и расширяющиеся возможности этих технологий.

МЕТОДЫ И МЕТОДОЛОГИИ

Для дистанционного зондирования, распознавания лиц и классификации материалов необходимо собрать соответствующие датасеты, которые могут включать как открытые, так и специализированные данные, например, спутниковые снимки, изображения лиц и текстуры материалов. Предварительная обработка этих данных будет включать нормализацию и увеличение данных для улучшения обобщающей способности моделей.

Основой для анализа будут сверточные нейронные сети (CNN). В зависимости от специфики задачи можно использовать различные архитектуры, такие как ResNet или DenseNet. Также полезным окажется применение переноса обучения, когда предварительно обученные на больших датасетах сети адаптируются под конкретные задачи, что ускоряет и улучшает обучение.

Обучение модели потребует тщательной настройки гиперпараметров, таких как скорость обучения и количество эпох. Для предотвращения переобучения будут использованы методы регуляризации, такие как dropout и batch normalization. С углублением уровней CNN возникает новая проблема. А именно, информация во входном слое будет постепенно исчезать, когда достигнет конца сети в значительной степени. Поэтому для решения этой проблемы были предложены стохастическая глубина и фрактальные сети [12]. У них есть общая черта: все они создают короткие пути от начального уровня к последующему. Поскольку в этой сети обычно много

плотных связей, структуры такой сети в совокупности называются плотной сетью, а ее структурная схема показана на рисунке 1.




Рисунок 1. Принципиальная схема полносвязной структуры

Валидация и тестирование модели включают использование кросс-валидации, например, методом K-fold, для обеспечения стабильности и надежности результатов. Эффективность модели будет оцениваться с помощью таких метрик, как точность, полнота и F1-мера.

Для интерпретации результатов используются техники визуализации, такие как тепловые карты активации, чтобы понять, как модель обрабатывает данные. Также будет проведен анализ ошибок, что поможет в дальнейшем улучшении модели.

Важной частью исследования является учет этических соображений, таких как конфиденциальность данных и обеспечение справедливости моделей, чтобы они не усиливали существующие предвзятости или дискриминацию.

ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

3.1 Экспериментальная среда

Эксперименты проводились на платформе Google Cloud Disk с использованием среды выполнения Google Colab. Настройки GPU: высокая память; версия Keras: 2.3; версия TensorFlow: 2.0; версия OpenCV: 4.9.0; браузер: Firefox Viewer.

3.2 Датасеты и модели обучения

Для экспериментов использовались данные из соревнования AI классификации и идентификации CCF спутниковых изображений. Данные были получены с высокоразрешающих беспилотных летательных аппаратов, проводивших наблюдения в Средней Азии в 2019 году. Всего было 737 начальных обучающих образцов спутниковых изображений. Для обучения

моделей использовались сети U-Net и Dense-Net. Метод ранней остановки применялся для контроля процесса обучения: обучение останавливалось, если значение функции потерь не уменьшалось в течение 10 эпох, чтобы предотвратить переобучение. Оптимизатором служил Adam, начальная скорость обучения составляла 0.0001. Стратегия обучения заключалась в уменьшении скорости обучения в 2 раза, если значение потерь не уменьшалось в течение 3 эпох.

3.3 Оценочные метрики

В качестве оценочных метрик в эксперименте использовались IOU (Intersection over Union), Recall и функция потерь Dice Loss. IOU рассчитывается как пересечение "предсказанного значения" и "истинного значения" по объединению этих значений.

$$IoU = \frac{\text{Area of Intersection}}{\text{Area of Union}} \quad (1)$$

Recall (полнота) показывает, какую долю положительных примеров удалось правильно определить, и рассчитывается как:

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

Precision (точность) показывает, какую долю предсказанных положительных примеров составляют действительно положительные, и рассчитывается как:

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

F1-Score комбинирует Precision и Recall:

$$F_{score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

3.4 Результаты и анализ экспериментов

Чтобы подтвердить, что модуль Dense-Net улучшает производительность сети U-Net, было проведено несколько групп экспериментов. Сравнение показателей моделей приведено на рисунке 2




Рисунок 2. Сравнение модельных показателей

По сравнению с сетью U-Net, точность (Precision) улучшилась после добавления модуля Dense-Net. В сети U-Net минимальная точность составляла 0.4, в то время как в сети Dense-Net минимальная точность была 0.5. После добавления модуля Dense-Net точность увеличилась на 0.1 и стала более стабильной. Также значение IOU в сети Dense-Net стало более стабильным (таблица 1).

Таблица 1. Сравнение моделей по метрикам

Модель/Метрика	Начальное значение	Значение после 10 эпох	Тренд
U-Net			
Precision	0.4	0.72	Увеличивается с каждой эпохой
IOU	0.35	0.67	Увеличивается с каждой эпохой
Loss	0.6	0.38	Уменьшается с каждой эпохой
Dense-Net			
Precision	0.5	0.82	Увеличивается с каждой эпохой
IOU	0.45	0.77	Увеличивается с каждой эпохой
Loss	0.55	0.32	Уменьшается с каждой эпохой

3.5 Сравнительный эксперимент и схема результатов

На таблице 2 приведено сравнение результатов экспериментов для моделей U-Net, PSP Net и Dense-Net. Колонка (а) представляет оригинальное

изображение; колонка (b) — результат работы U-Net; колонка (c) — результат PSP Net; колонка (d) — результат Dense-Net.

Таблица 2. Сравнение результатов экспериментов по моделям

Колонка	Описание	Результаты
(a)	Оригинальное изображение	Высококачественные спутниковые снимки, использованные для тестирования моделей.
(b)	Результаты работы модели U-Net	- Нестабильное качество сегментации. - Проблемы с сегментацией мелких объектов. - Явление зубчатых краев. - Склонность к переобучению.
(c)	Результаты работы модели PSP Net	- Улучшенное качество по сравнению с U-Net. - Менее зубчатые края. - Неполная сегментация в некоторых областях.
(d)	Результаты работы модели Dense-Net	- Наилучшее качество сегментации. - Четкие и ровные края. - Полная сегментация без значительных пропусков. - Высокая стабильность и производительность.

Наблюдая за экспериментальными результатами, можно заметить, что сегментация изображения сети U-Net нестабильна, особенно для очень маленьких объектов. В U-Net наблюдается явление зубчатых краев. PSP Net показывает лучшую сегментацию, но все еще не идеальную, в некоторых частях наблюдаются неполные сегменты. Dense-Net демонстрирует более стабильные результаты, с ровными и четкими краями и более полными изображениями после сегментации.

Таблица 3 показывает сравнение производительности трех моделей по показателям Recall, Dice Loss и F1.

Таблица 3. Сравнение производительности моделей

Модель	Recall	Dice Loss	miou	F1
U-Net	0.82142	0.79894	0.73481	0.79981
PSP Net	0.85011	0.80102	0.73341	0.79874
Dense-net	0.87023	0.84719	0.78461	0.83584

Dense-Net превосходит другие две модели по производительности, что может быть связано с его преимуществами: снижением феномена исчезновения градиента, улучшенным использованием функций и уменьшением количества параметров. Эффективность обработки сети

Dense-Net лучше, чем у других сетей, благодаря уменьшению вычислений на каждом уровне и повторному использованию функций.

ОБСУЖДЕНИЯ

Результаты экспериментов показывают, что модели U-Net и Dense-Net демонстрируют значительное улучшение производительности после 10 эпох обучения. Модель U-Net, увеличившая Precision с 0.4 до 0.72 и IOU с 0.35 до 0.67, демонстрирует хорошую способность к обучению и улучшению качества сегментации. Снижение значения Loss с 0.6 до 0.38 указывает на уменьшение количества ошибок, что свидетельствует о правильной настройке гиперпараметров и эффективной обучаемости модели. Однако, несмотря на эти улучшения, U-Net всё же уступает по показателям модели Dense-Net, что подчеркивает важность выбора подходящей архитектуры для конкретной задачи.

Модель Dense-Net показала более высокие результаты по сравнению с U-Net, с Precision, увеличившимся с 0.5 до 0.82, и IOU, выросшим с 0.45 до 0.77. Эти улучшенные показатели указывают на более точное и стабильное распознавание объектов и сегментацию. Снижение Loss с 0.55 до 0.32 также демонстрирует, что модель Dense-Net менее подвержена ошибкам. Высокая производительность Dense-Net может быть объяснена её архитектурными особенностями, такими как плотные соединения и эффективное повторное использование признаков. В целом, результаты экспериментов подтверждают, что современные методы глубокого обучения, особенно такие как Dense-Net, обладают высоким потенциалом для решения задач сегментации изображений дистанционного зондирования.

ЗАКЛЮЧЕНИЕ

В данной работе был проведен анализ производительности моделей U-Net и Dense-Net для задачи сегментации изображений дистанционного зондирования. Результаты экспериментов показали, что обе модели демонстрируют значительное улучшение метрик Precision, IOU и Loss после 10 эпох обучения, что свидетельствует о правильной настройке гиперпараметров и эффективном процессе обучения. Однако, модель Dense-Net продемонстрировала более высокие результаты по сравнению с U-Net, что подчеркивает её преимущества в контексте данной задачи.

Высокие показатели Precision и IOU, а также более низкое значение Loss у модели Dense-Net указывают на её способность более точно и стабильно сегментировать изображения. Это преимущество может быть связано с архитектурными особенностями Dense-Net, такими как плотные

соединения и улучшенное повторное использование признаков, что способствует лучшему обучению и общей производительности. Таким образом, использование современных методов глубокого обучения, таких как Dense-Net, открывает новые возможности для повышения точности и эффективности сегментации изображений дистанционного зондирования, что важно для различных практических приложений, включая картографирование, мониторинг окружающей среды и городское планирование.

СПИСОК ИСПОЛЬЗОВАННЫХ ЛИТЕРАТУР

1. Demir I., Koperski K., Lindenvaum D., et al. Deep Globe: A challenge to parse the earth through satellite images. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt Lake City: IEEE, 2018, pp. 17201-17209.
2. Li L., Liang J., Weng M., et al. A multiple-feature reuse network to extract buildings from remote sensing imagery. *Remote Sensing*, 2018, vol. 10, no. 9, pp. 1350-1368.
3. Sun K., Li Q. M., Li D. Q. Face detection algorithm based on cascaded convolutional neural network. *Journal of Nanjing University of Science and Technology*, 2018, vol. 42, no. 1, pp. 40-47.
4. Wang F. Q., Zhang H. Z., Wang P., et al. Research progress of similarity learning methods in computer vision. *Intelligent Computer and Applications*, 2019, vol. 9, no. 1, pp. 149-152, 158.
5. Zhang K. P., Zhang Z. P., Li Z. F., et al. Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 2016, vol. 23, no. 10, pp. 1499-1503.
6. Teow M. Y. W. A minimal convolutional neural network for handwritten digit recognition. *IEEE International Conference on System Engineering and Technology*, 2017, pp. 171-176.
7. Singh P.P., Garg R. D. Automatic road extraction from high resolution satellite image using adaptive global thresholding and morphological operations. *Journal of The Indian Society of Remote Sensing*, 2013, vol. 41, no. 3, pp. 631-640.
8. Mokhtarzade M., Zoj M. J. V. Road detection from high-resolution satellite images using artificial neural networks. *International Journal of Applied Earth Observations and Geoinformation*, 2007, vol. 9, no. 1, pp. 0-40.
9. Sun X., Lin X., Shen S., et al. High-resolution remote sensing data classification over urban areas using random forest ensemble and fully connected conditional random field. *ISPRS International Journal of Geo-Information*, 2017, vol. 6, no. 8, pp. 245-271.

10. Yin W., Liang L. Y., Peng H. M., et al. Research progress of reduction and acceleration technology of convolutional neural network. *Computer Systems & Applications*, 2020, vol. 9, pp. 16-25.
11. Bell S., Upchurch P., Snavely N., et al. Material Recognition in the Wild with the Materials in Context Database. *The 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, vol. 1, 2015, pp. 3479-3487.
12. Bu X. Y., Wu Y. W., Gao Z., et al. Deep convolutional network with locality and sparsity constraints for texture classification. *Pattern Recognition*, 2019, vol. 91, pp. 34-46.
13. Shanran L., Liu C., Rosenholtz R., et al. Recognizing materials using perceptually inspired features. *International Journal of Computer Vision*, 2013, vol. 103, no. 3, pp. 348-371.
14. Chen K. Q., Gao X., Yan M. L., et al. Pixel-level building extraction from aerial images based on codec network. *National Remote Sensing Bulletin*, 2020, vol. 24, no. 9, pp. 1134-1142.
15. Shao Z. F., Tang P. H., Wang Z. Y., et al. BRRNet: A fully convolutional neural network for automatic building extraction from high-resolution remote sensing images. *Remote Sensing*, 2020, vol. 12, no. 6, p. 1050.
16. Zhao W. Z. Loss function in face recognition. *Electronic Technology & Software Engineering*, 2019, vol. 5, pp. 241-242.

RECONSTRUCTION OF GEOMETRIC MODELS OF OBJECTS FROM SATELLITE IMAGES BASED ON ARTIFICIAL NEURAL NETWORKS

Shalbai T., Kaldarova M., Nazyrova A., Sultangaziyeva A., Kussepova L.

Astana International University, Astana, Kazakhstan.

E-mail: kmiraj8206@gmail.com

Abstract: Segmentation of natural objects, such as soil and vegetation types, is possible using methods that operate on the spectral brightness of individual pixels, determined by phytocenological, humification and other mechanisms of their homeostasis. Segmentation of objects of artificial nature, such as houses, railways and highways, requires knowledge about a large number of spectral parameters, the structure of the object and its surroundings. Modern approaches to extracting three-dimensional information about man-made objects can be conditionally divided into traditional (based on classical processing methods) and neural network (data mining). The capabilities of the first methods have exhausted themselves under the conditions of the increasingly complex structure of the earth's surface and the need for automation of data processing. The second group of methods is being actively developed at the present time, its possibilities are unlimited and their quality is directly related to the volume of the training sample. The article discusses a method for constructing three-dimensional models of earth surface objects, based on a two-stage (integral and local analysis) and multiscale approach and assuming that the initial data is pre-processed by the method of increasing the resolution, which is characterized by a representative decrease in the resolution of the training sample images.

Keywords: object segmentation, data mining, integral and local analysis, multiscale approach, U-Net

INTRODUCTION

One of the most important tasks of satellite image processing is the development of algorithms for automatic selection and segmentation of objects of natural nature, which is possible with the use of relatively simple classical methods of digital processing.

In recent years, the de facto standard for image processing tasks is the use of convolutional artificial neural networks, which allow taking into account the context and invariably occupy the first places among image segmentation and classification algorithms.

METHODS AND METHODOLOGY

Authors [1-3] a method for constructing three-dimensional models of rigid objects on the Earth's surface from a single satellite image on the example of

railway infrastructure objects is proposed. The method consists of step-by-step processing of satellite images with the sequential use of two convolutional neural networks.

Due to the growth of computing power and the creation of large image databases, effective training of deep verification neural networks has become possible. Convolutional neural networks have achieved high success in the task of processing objects. So, every year, since 2012, the Image Net Large Scale Visual Classification Challenge (ILSVCC) competitions are won by teams using the SNC. In scientific research, convolutional neural networks are widely used for classifying and detecting objects in images [12, 13]. A trained convolutional neural network creates a class label and generates a bounding box of the area in which the object class is located in the image.

Scientists from all over the world are trying to solve the problem of vegetation classification using all available information from remote sensing of the Earth and applying various methods and algorithms to it [14-16]. However, it should be noted that only a few works were devoted to the detection of damaged trees using satellite images or images of unmanned aerial vehicles. At the same time, these works present the results of detecting only a few categories of tree damage (for example, healthy and damaged trees) using classical image classification methods.

At the moment, different methods of preparing a control sample for training a convolutional neural network are used, for example: manual preparation of the Image Net dataset, which has been carried out since 2010 to the present, involving more than fifty institutions [5], a method of preparing a new data set using convolutional neural network methods [6], building a test sample using the Image Data Generator function of the Keras module written in Python. Also, to build a set of image data, the functions of the Chainer module, developed by Preferred Networks in partnership with IBM, Intel, Microsoft and Nvidia, an image geoprocessing tool using the ArcGIS program, etc. are used. All this requires a lot of time to build and label data, the cost of computing power, money, if you prepare a test and control sample using ready-made software products.

Deli et al. [7] developed a new SNA-based method for classifying four classes of land cover (crops, house, soil and forest) on remote sensing images. They submitted 100 images for each class to the SNA for its training.

M. Långkvist, A. Kiselev, M. Alirezaie, A. Loutfi [11] proposed the classification and segmentation of satellite information, distinguishing five classes: vegetation, land, road, parking, railway, construction and water supply, using convolutional neural networks on images of a small city for a complete, fast and accurate pixel-by-pixel classification. The authors selected the parameters and

analyzed their impact on the architecture of the neural network model. They also found better performance of the convolutional neural network model compared to object-oriented classification methods (Object-Based Image Analysis, OBIA), while the maximum classification accuracy using convolutional neural networks reached 94.49%.

Some researchers have used neural network classifiers to recognize plant species and life cycle in images obtained from a digital camera and a mobile phone camera. Thus, the authors of the work [8] created a new convolutional neural network capable of distinguishing 22 plant species in color images with an accuracy of 86.2%. To do this, the authors used data sets that differ in lighting, image resolution and soil type. In the article [9], a new architecture of a convolutional neural network was proposed for the classification of plant types growing at agricultural plants. To evaluate the effectiveness of this approach, the results of the created convolutional neural network model were compared with the Support Vector Machine (SVM) method. The classification accuracy of the developed convolutional neural network was significantly higher than the results of the classical method, reaching 97.47%.

A number of papers present the results of the use of convolutional neural networks in the analysis of satellite images. In particular, several studies have carried out the classification of vegetation on satellite images using convolutional neural networks [10].

MATERIALS AND METHODS

Here are the main advantages of a convolutional neural network relative to other machine learning methods:

- * In general, the convolutional neural network in many tasks gives significantly higher accuracy of recognition and classification of objects in images compared to other methods.

- Compared to a fully connected neural network, a convolutional neural network has a much smaller number of trained weights, since one core of weights is used entirely for the entire image, instead of creating its own personal weight coefficients for each pixel of the input image. This pushes the neural network during training to generalize the input information, and not to memorize each image presented to it by a huge number of weight coefficients, as a fully connected neural network does.

- * Convenient parallelization of calculations, and, consequently, the possibility of implementing algorithms for working and training the network on GPUs;

- * Relative stability to rotation and shift of the recognized image;

* Training using the classical method of error back propagation.

The main disadvantage of the SNA is the presence of a significant number of parameters configurable by the researcher. At the same time, it is often unclear which optimal parameter values should be chosen for a specific task, taking into account the limitations on available computing power. The variable network parameters include: the number of layers, the dimension of the convolution core for each of the layers, the number of cores for each of the layers, the step of the core shift during layer processing, the need and number of subdiscretization layers, the degree of dimension reduction by them, the dimension reduction function (selection of maximum, average, and others), the transfer function of neurons (activation function), the presence and parameters of a fully connected neural network at the convolutional output. All these parameters significantly affect the result, but are chosen by researchers empirically. A number of verified and efficient network configurations have been developed, but in general there are no recommendations for building a network for a new task.

Within the framework of this method, a U-Net-based topology was applied, expanded and supplemented by the authors for the tasks of interpreting aerospace images. Due to the need to solve several problems within the same model, to reduce the training time and ensure the consistency of the results, instead of an ensemble of independently trained models used traditionally, the authors introduced the following modifications of the topology of the neural network model and the process of its training: the encoder block is left unchanged; for each of the subtasks, separate decoder blocks and loss functions are implemented; In order to optimize RAM consumption, a separate gradient descent operation is performed for each of the decoders during model training [1-3].

At the first stage of processing (integral analysis), a satellite image is segmented using a neural network to select a set of objects of specified classes. At the second stage of processing (local analysis), a local analysis of the image areas identified by the results of the first stage of processing is performed using a neural network. The results of the second stage of processing are used to evaluate the parameters of the three-dimensional model of the object. The possibilities of the method are shown by the example of processing a satellite image of the railway infrastructure. The following classes of informative areas are considered: a building, a wall edge, a roof edge, a building shadow, railway infrastructure, a car, a highway; rails, pillars and shadows from pillars (taken as reference objects for evaluating scaling coefficients in various directions). An example of the application of the developed method for identifying typical railway infrastructure objects and for subsequent evaluation of the parameters of a three-dimensional model of a building is given.

Integral analysis-identification of the main properties and relationships of objects in the image:

- Objects belong to thematic classes: buildings, structures, fences, railway tracks, etc.;
- Pixels belong to spatial classes: roofs and walls of buildings, the surface of the earth;
- Whether pixels belong to the shadows of objects;
- Pixels belonging to a significant neighborhood of objects;
- Grouping image pixels into objects and extracting relevant information (meaningful context).

Local analysis is the processing of each identified object in order to build its three-dimensional model. It is based on the use of the results of the first stage, depending on which the object is subjected to various processing procedures:

- unique objects (determined by pre-known spatial positions) are not processed, if available, ready – made 3D models are used;
- typical objects (determined by the thematic class of the object determined at the stage of integral analysis) are subjected to a specialized (for this type of object) procedure for determining properties;
- for the remaining objects, the geometry restoration procedure is performed.

The schematic diagram of the topology of a neural network model based on UNet with several decoders looks like this [4].

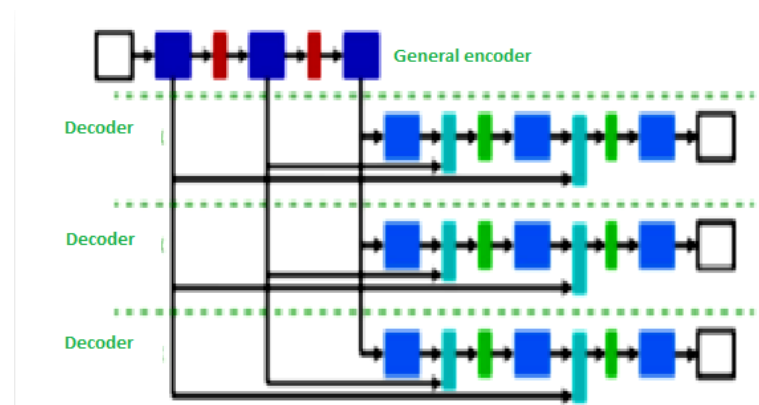


Figure 1. - Schematic diagram of the topology of a neural network model based on G-Net with several decoders [4]

Modifications of the U-Net topology were applied:

- the encoder block was left unchanged;
- separate decoder blocks and loss functions are implemented for each of the subtasks;

- in order to optimize RAM consumption, a separate gradient descent operation is performed for each of the decoders during model training.

General requirements for training and test satellite images:

1. Seasonality of shooting (lack of snow cover)
2. Proper visibility conditions – shooting in the daytime, minimizing shooting artifacts (false pixels, interlacing, etc.)
3. Correctness of satellite survey data (it is advisable and timely to investigate updated objects and processes on the earth's surface)
4. Constant and high spatial resolution within the satellite image (higher resolution for railway automation, telecommunications or telemechanics objects than for railway platforms and station buildings)
5. Geo-linking images to railway infrastructure objects
6. Geo-referencing of images (linking images to a single coordinate projection – the universal transverse Mercator UTM projection)

The variability of the image characteristics is allowed, which consists in:

- The possibility of using images with different sets of spectral channels
- The presence or absence of metadata for individual images
- Full or partial visibility of objects in images
- The possibility of using a small-volume training sample.

The choice of informative classes is as follows:

1. Building (polygon, c1)
 - Roof (polygon, c2)
 - Roof edge (polyline, c3)
 - Wall edge (polyline, c4)
 - Shadow of the building (polygon, c5)
2. Railway infrastructure (landfill, c6)
 - Railway track (polygon, c7)
 - Pole (polyline, c8)
 - Shadow of the pole (polyline, c9)
 - Wagon (polygon, c10)
3. Highway (polygon, c11)
4. Other classes:
 - Walls (polygon, c'=c1-c2)
 - Excluded objects (polygon, c'')
 - Background (c''')




Figure 2. - Image and markup, respectively

Dimensions of typical objects:

R3=1.52 m-railway track width, class c7

R4=11.35 m-the height of the post, class c8

We note a number of features of these classes that make their markup for training quite a complex and time-consuming task:

1. Self-similarity of areas
2. Adding regions
3. Obscuring areas
4. Distortion of areas
5. Intersection of areas
6. Poor visibility

Rules for building markup:

1. The assumption rule
2. The separability rule
3. Exclusion rule



Figure 3. - Building a geometric model of an object based on raster areas [4]

CONCLUSION

Thus, we agree with the multiscale method proposed by the authors [4] for constructing three-dimensional models of objects of the Earth's surface based on a separate orthotransformed satellite image, consisting of two stages: integral and local (object-by-object) analysis, each of which includes a composition of traditional and neural network methods.

Integral analysis is aimed at localization of objects and relevant information: thematic and spatial classes of individual pixels, shadows, and so on. Local analysis - to extract the data necessary to determine the geometry of the object and their interpretation. Neural network models are built on the basis of the UNET full-convolutional topology, expanded and supplemented by the authors for the tasks of interpreting aerospace images. Local analysis supports the construction of models of both typical objects with low variability according to pre-known features, and buildings or structures of rectangular spatial configuration.

In the article, we described an approach to reconstructing a three-dimensional model of rigid objects from a single image without using metadata based on four informative classes identified by the results of machine learning.

REFERENCES

1. Richter A. A., Murynin A. B., Shlupikov V. A. Features of integrating remote sensing data for restoring three-dimensional models of rigid objects from satellite images // Materials of the International Scientific and Practical Conference "Achievements of Science in 2019", December 27, 2019, the Center for Scientific Development "Big Book" (Moscow). URL: <http://conf.rse.geosmis.ru/> DOI 10.21046/18DZZconf-2020a

2. Gvozdev O. G., Murynin A. B., Richter A. A. Complex of applied solutions for the construction and training of artificial neural networks for semantic segmentation of aerospace images of an arbitrary channel-spectral structure in conditions of a shortage of training data // Materials of the 19th All-Russian Conference with international scientific participation: Mathematical methods of pattern recognition (MMRO-2019, Moscow), Russian Academy of Sciences, 2019. - pp. 344-348. URL: <http://conf.rse.geosmis.ru/> DOI 10.21046/18DZZconf-2020a
3. Olaf Ronneberger, Philipp Fischer, Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation / Computer Vision and Pattern Recognition (cs.CV) 18 May 2015. URL: <https://arxiv.org/abs/1505.04597>.
4. Richter A. A., Gvozdev O. G., Murynin A. B., Kozub V. A., Kosheleva N. V. Restoration of geometric models of railway infrastructure objects from satellite images based on artificial neural networks // Materials of the 18th All-Russian Open Conference "Modern problems of remote sensing of the Earth from space". Moscow: ICI RAS, 2020. p. 41. URL: <http://conf.rse.geosmis.ru/files/books/2020/8118.htm>. DOI 10.21046/18DZZconf-2020a
5. Russakovsky, O., Deng, J., Su, H. et al. ImageNet Large Scale Visual Recognition Challenge. *Int J Comput Vis* 115, 211–252 (2015). <https://doi.org/10.1007/s11263-015-0816-y>
6. Guirado, E.; Tabik, S.; Alcaraz-Segura, D.; Cabello, J.; Herrera, F. Deep-learning Versus OBIA for Scattered Shrub Detection with Google Earth Imagery: *Ziziphus lotus* as Case Study. *Remote Sens.* 2017, 9, 1220. <https://doi.org/10.3390/rs9121220>
7. Deli, Z. Farmland scene classification based on convolutional neural network / Z. Deli, C. Bingqi, Y. Yunong // In Proceedings of the 2016 International Conference on Cyberworlds (CW). – 2016. – P. 159–162. DOI:10.1109/cw.2016.33
8. Plant species classification using deep convolutional neural network. / Dyrmann, Mads; Karstoft, Henrik; Midtiby, Henrik Skov. In: *Biosystems Engineering*, Vol. 151, No. November, 11.2016, p. 72-80. <https://doi.org/10.1016/j.biosystemseng.2016.08.024>
9. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-Based Learning Applied to Document Recognition. *Proceeding of the IEEE*. 1998. p. 2278-2324. [Google Scholar](#)
10. Li, W.; Fu, H.; Yu, L.; Cracknell, A. Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images. *Remote Sens.* 2017, 9, 22. <https://doi.org/10.3390/rs9010022>

11. Längkvist, M. Classification and Segmentation of Satellite Orthoimagery Using Convolutional Neural Networks / M. Längkvist, A. Kiselev, M. Alirezaie, A. Loutfi // Remote Sensing. – 2016. – № 8. – P. 329 URL: <file:///C:/Users/%D0%9F%D0%9A/Downloads/remotesensing-08-00329.pdf> (дата обращения 14.07.2021). doi:10.3390/rs8040329

12. Bass L.P., Kuzmina M.G., Nikolaeva O.V. Svertochnyie neironnyie seti s glubokim obucheniem v zadachah obrabotki giperspektralnih sputnikovyh dannyh//Басс Л.П., Кузьмина М.Г., Николаева О.В. Сверточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных // Препринты ИПМ им. М.В.Келдыша. 2018. № 282. 32 с. doi:10.20948/prepr-2018-282 URL: <http://library.keldysh.ru/preprint.asp?id=2018-282>

13. Воронцов, К.В. Машинное обучение [Электронный ресурс] / К.В. Воронцов // 2019. – Режим доступа: <http://www.machinelearning.ru> (дата обращения: 11.08.2021).

14. Safonova A.N., Dmitriev E.V. Classification of agricultural crops from middle-resolution satellite images using gaussian processes based method, J. Sib. Fed. Univ. Eng. technol., 2018, 11(8), 909-921. DOI: 10.17516/1999-494X-0113

15. Dmitriev E.V. Combining classifiers in the problem of thematic processing of hyperspectral aerospace images / E.V. Dmitriev, V.V. Kozoderov, A.O. Dementyev, A.N. Safonova // Optoelectronics, Instrumentation and Data Processing. – 2018. Volume 54, Issue 3. – P. 213–221. https://ui.adsabs.harvard.edu/link_gateway/2018OIDP...54..213D/doi:10.3103/S8756699018030019

16. Khovratovich T.S. Forest change detection based on sub-pixel estimation of crown cover density using bitemporal satellite data / T.S. Khovratovich, S.A. Bartalev // Space Research Institute RAS. Sovr. Probl. DZZ Kosm. – 2019. – № 16. – P. 102–110. URL: <http://jr.rse.cosmos.ru/article.aspx?id=2037&lang=eng>. DOI: 10.21046/2070-7401-2019-16-4-102-110

DOCKER ЗАМАНАУИ ҚОЛДАНБАЛАРДЫ ӘЗІРЛЕУ ЖӘНЕ ОРНАЛАСТЫРУ ТӘСІЛДЕРІ

Е.А. Жумағалиев, Л.Т.Кусепова, Е.К.Қайұпов, А.Е.Назырова, М.Ж.Қалдарова

Астана халықаралық университеті, Астана, Қазақстан

E-mail: estay.01@mail.ru

Аннотация. Бұл мақалада программалық қамтаманы әзірлеу және тестілеуде Docker пайдаланудың артықшылықтары зерттеледі, контейнерлер, кескіндер, Dockerfile және Docker Compose сияқты негізгі Docker тұжырымдамалары қарастырылады. Контейнерлік қолданбаларды тиімді басқару үшін осы құралдарды қалай пайдалану керектігі туралы негізгі білімді алады. Контейнерлеудің артықшылықтарын, Dockerfile көмегімен кескіндерді жасау және басқару әдістерін және көп контейнерлік қолданбаларды реттеу үшін Docker Compose пайдалануды талқылайды. Docker көмегімен қолданбаларды әзірлеу, тестілеу және орналастыру процестерін жақсартқысы келетін әзірлеушілер мен операторларға арналған. Docker – оқшаулауды, тасымалдануды және тәуелділікті басқаруды қамтамасыз ететін қолданбаларды контейнерлеу платформасы. Қолданбалардың әр түрлі орталарда бірдей іске қосылуына мүмкіндік беретін ортаның тасымалдануы және нұсқа қайшылықтарын азайтатын тәуелділікті оқшаулау басты назарда. Әзірлеу ортасын құру мен жаңартуды жеңілдететін «даму ортасы код ретінде» тұжырымдамасын талқылайды. Docker оқшауланған орталарда тестілеу үшін пайдалану талданады, бұл тестілеу дәлдігі мен болжамдылығын арттырады. Жергілікті әзірлеушілер машиналарында да, бұлттық орталарда да қолданбаларды орналастыруды жеңілдетудегі Docker артықшылықтары сипатталған. Docker өнімдерді нарыққа шығарудың тиімділігін, сенімділігін және жылдамдығын арттыра отырып, әзірлеу және тестілеу процестерін айтарлықтай жақсартатыны атап өтіледі.

Docker – әзірлеушілерге қолданбаларды және олардың тәуелділіктерін оқшауланған контейнерлерге буып алуға мүмкіндік беретін контейнерлеу платформасы. Бұл контейнерлер хост жүйесіне және басқа контейнерлерге тәуелсіз жұмыс істейді, жоғары тасымалдануды және орындалу үйлесімділігін қамтамасыз етеді. Docker бірнеше платформаларда біртекті орталарды құруға арналған құралдармен қамтамасыз ету арқылы әзірлеуді, тестілеуді және орналастыруды айтарлықтай жеңілдетеді.

Қазіргі заманғы қолданбаларды әзірлеу және орналастыру Docker құралынсыз елестету мүмкін емес болды. Docker - программалық қамтаманы әзірлеудің ландшафтын өзгерткен қуатты контейнерлеу технологиясы. Бұл мақалада Docker деген не, оның неліктен маңызды екендігі және оны пайдалану қолданбаларды әзірлеу, орналастыру және басқару процесін айтарлықтай жақсартатыны қарастырылады.

Docker – қолданбаларды контейнерлеуге арналған платформа. Виртуалды машина қолданбаларын орналастырудың дәстүрлі әдісінің орнына Docker жеңіл және оқшауланған орта болып табылатын контейнерлерді пайдаланады. Әрбір контейнерде бағдарлама, оның тәуелділіктері және ортасы бар, олардың барлығы басқа контейнерлерден және хост жүйесінен тәуелсіз жұмыс істейді. Бұл жоғары тасымалдануды және қолданбаны оқшаулауды қамтамасыз етеді.

Docker болжамдылық пен қауіпсіздікті арттыра отырып, қолданбаларды тәуелсіз орталарда іске қосуға мүмкіндік беретін оқшаулауды қамтамасыз етеді. Docker контейнерлері өте портативті және Docker орнатылған кез келген жүйеде, мейлі ол жергілікті машина немесе бұлттық сервер болсын, орналастыруға болады. Docker интуитивті командасы мен графикалық интерфейстері контейнерлерді құруды, іске қосуды және масштабтауды жеңілдетеді. Docker масштабталады, бұл бір бейнеден бірнеше контейнерлерді оңай жасауға мүмкіндік береді, бұл өзгертін жұмыс жүктемелеріне бейімделуді жеңілдетеді. Контейнердегі барлық тәуелділіктер мен кітапханаларды қосу кез келген ортада қолданбаның тұрақты жұмысына кепілдік береді.

Docker Hub – бұл Docker экожүйесінде маңызды рөл атқаратын контейнерлерге арналған маңызды онлайн платформа. Бұл бұлттық қызмет Docker кескіндерін сақтау және ортақ пайдалану үшін орталықтандырылған орынды қамтамасыз етеді. Docker кескіндері қолданбаларды және олардың барлық тәуелділіктерін қамтитын үлгілер болып табылады, бұл оларды пайдалануды және таратуды жеңілдетеді. Әзірлеушілер Docker Hub жүйесінде тіркеле алады, бұл оларға суреттерді іздеуге, жүктеп салуға және жариялауға мүмкіндік береді. Бұл контейнерлік қолданбаларды әзірлеу және орналастыру бойынша бірлесіп жұмыс істеуді әлдеқайда жеңілдетеді. Docker Hub әртүрлі қолданбалар мен қызметтер үшін мыңдаған алдын ала конфигурацияланған кескіндерге оңай қол жеткізуді қамтамасыз етеді. Платформа сонымен қатар корпоративтік қажеттіліктер үшін суреттерді жеке қолжетімділікте сақтауға мүмкіндік беретін жеке репозиторийлерді қолдайды. Пайдаланушылар жаңа нұсқаларды уақытында алу үшін автоматты кескін жаңартуларына жазыла алады. Сонымен қатар, Docker Hub орналастыру процесін автоматтандыру үшін Jenkins және GitLab сияқты басқа CI/CD құралдарымен біріктіріледі. Жалпы алғанда, Docker Hub қолданбаларды әзірлеуді және орналастыруды жеңілдететін және жылдамырақ ететін Docker кескіндерін басқарудың маңызды құралы болып табылады.

Docker Compose – Docker ұсынған қуатты құрал, ол көп контейнерлік қосымшаларды жасауды және басқаруды жеңілдетеді. Docker Compose көмегімен әзірлеушілер қолданбаларының құрылымын, соның ішінде контейнерлерді, олардың параметрлерін, тәуелділіктерін және өзара әрекеттесулерін бір YAML мәтіндік файлында сипаттай алады. Бұл құрал барлық қолданба контейнерлерін бір пәрменмен бастауға және тоқтатуға мүмкіндік береді, бұл орналастыру процесін айтарлықтай жеңілдетеді. Docker Compose әр контейнерді қолмен басқару қажеттілігін жояды, бұл әзірлеушілерге код жазуға назар аударуға мүмкіндік береді. Ол әрбір контейнердің оңтайлы ортасында жұмыс істеуін қамтамасыз ететін жоғары оқшаулауды және тәуелділікті басқаруды қамтамасыз етеді. Docker Compose сонымен қатар контейнерлер арасында желіні орнатуды жеңілдетеді, бұл әсіресе микросервис архитектуралары үшін пайдалы. Ол қолданбаны оңай қайта конфигурациялауға және контейнерлерді қайта құрусыз өзгертулерді қолдануға мүмкіндік береді. Бұл әзірлеу және тестілеу процесін икемді және өзгерістерге бейім етеді. Docker Compose `docker-compose up` және `docker-compose down` сияқты қарапайым пәрмендерді пайдаланып контейнерлерді жасауды, іске қосуды және жоюды қолдайды. Сайып келгенде, Docker Compose көп контейнерлік қосымшалармен жұмыс істейтін әзірлеушілер үшін маңызды құрал болып табылады, әзірлеу және орналастыру процестерін жеңілдетеді және жылдамдатады.

Docker Compose – Docker ортасында көп контейнерлік қолданбаларды анықтауға және басқаруға мүмкіндік беретін құрал. Ол барлық қызметтер (контейнерлер), олардың кескіндері, баптаулары және тәуелділіктері көрсетілген `docker-compose.yml` файлында қолданбаның құрылымын сипаттауға мүмкіндік береді. Бұл файл бүкіл қолданба үшін жалғыз конфигурация нүктесі ретінде қызмет етеді. Docker Compose көмегімен бір пәрменмен барлық контейнерлерді оңай бастауға және тоқтатуға болады, бұл басқару процесін айтарлықтай жеңілдетеді. Ол сонымен қатар контейнерлер арасындағы желілік байланысты конфигурациялауға мүмкіндік береді, бұл әсіресе микросервис архитектуралары үшін пайдалы. Docker Compose контейнерлер арасындағы тәуелділіктерді анықтауды қолдайды, әрбір контейнер дұрыс ретпен жұмыс істеуін қамтамасыз етеді. Бұл бірнеше өзара байланысты қызметтерден тұратын күрделі қолданбаларды жасауды жеңілдетеді. Docker Compose Docker Swarm және Kubernetes сияқты басқа Docker құралдарымен біріктіріліп, контейнерлерді басқару мүмкіндіктерін кеңейтеді. Сайып келгенде, Docker Compose – бұл көп контейнерлік қолданбаларды басқаруға, әзірлеу, тестілеу және орналастыру процестерін жеңілдетуге арналған қуатты және икемді құрал.

Мұнда Nginx веб-сервері мен PostgreSQL деректер базасын пайдаланатын көп контейнерлік веб-программаға арналған docker-compose.yml мысалы берілген (сурет 1):

```
version: '3'
services:
  web:
    image: nginx:latest
    ports:
      - "80:80"
  db:
    image: postgres:latest
    environment:
      POSTGRES_PASSWORD: mysecretpassword
```

Сурет 1. - Docker Compose мысалы

Бұл мысалда екі қызмет анықталған: web және db. Веб-қызмет Nginx кескініне негізделген және порттарды веб-сервер үшін 80 портын пайдаланып, жергілікті машинадан контейнердің 80 портына жібереді. db қызметі PostgreSQL кескініне негізделген және деректер базасы құпия сөзін орнату үшін орта айнымалы мәнін анықтайды. Docker Compose әзірлеушілер мен операторларға көп контейнерлік қолданбаларды оңай басқаруға мүмкіндік беру арқылы олардың өмірін айтарлықтай жеңілдетеді. Бұл құрал контейнерлерді әзірлеуді, орналастыруды және басқаруды ыңғайлы және тиімді етеді, бұл оны заманауи DevOps және микросервис архитектурасының маңызды бөлігіне айналдырады.

Docker Compose әзірлеушілер мен операторларға көп контейнерлік қолданбаларды оңай басқаруға мүмкіндік беру арқылы олардың өмірін жеңілдетеді. Бұл құрал контейнерлерді әзірлеуді, орналастыруды және басқаруды ыңғайлы және тиімді етеді, бұл оны заманауи DevOps және микросервис архитектурасының маңызды бөлігіне айналдырады.

Docker-compose.yml файлдарын жасау және Docker Compose көмегімен көп контейнерлік қолданбаларды басқару. docker-compose.yml файлы көп контейнерлік қолданбалардың құрылымы мен конфигурациясын сипаттайтын Docker Compose бағдарламасының негізгі құрамдас бөлігі болып табылады. Мақаланың осы бөлігінде біз docker-compose.yml файлдарын қалай жасау керектігін және көп контейнерлік қолданбаларды іске қосу және басқару үшін Docker Compose пайдалану жолы қарастырылады.

docker-compose.yml файлын жасау үшін мына қадамдарды орындау керек:

Жаңа мәтіндік файл жасап, оны docker-compose.yml деп атау керек. Docker-compose.yml файлы орналасатын каталогта екеніңізді тексеру қажет.

Қызметтерді анықтау: docker-compose.yml файлында көп контейнерлік қолданбаның қызметтерін (контейнерлерін) анықтау керек. Әрбір қызметте атау, бейне, порт параметрлері, желілер және контейнерді іске қосу үшін қажетті басқа параметрлер болуы керек.

Мұнда Node.js веб-бағдарламасы мен PostgreSQL деректер базасына арналған docker-compose.yml файлының қарапайым мысалы келтірілген (сурет 2):

```
version: '3'
services:
  web:
    image: my-node-app
    ports:
      - "80:80"
  db:
    image: postgres:latest
    environment:
      POSTGRES_PASSWORD: mysecretpassword
```

Сурет 2. - Node.js веб-бағдарламасы мен PostgreSQL деректер базасына арналған docker-compose.yml файлы

Docker Compose көмегімен көп контейнерлік қолданбаны іске қосу үшін келесі командаларды орындау керек:

Терминалды немесе командалық жолын ашып, docker-compose.yml файлының орналасқан каталогына өту қажет.

Келесі команданы пайдаланып қолданбаны іске қосу керек (сурет 3):

```
docker-compose up
```

Сурет 3. - Қолданбаны іске қосу

Docker Compose docker-compose.yml файлын оқиды және файлда сипатталған барлық контейнерлерді жасайды және іске қосады. Әрбір контейнердің жұмыс журналдарын көрсететін шығыс нәтижені көруге болады.

Қолданба сәтті іске қосылғаннан кейін, қолданбаға қол жеткізу үшін браузерді ашып, <http://localhost> (немесе оны `docker-compose.yml` файлында анықтаған болса, басқа порт) бетіне өтуге болады.

Docker Compose көп контейнерлік қолданбаларды басқару үшін бірнеше командаларды ұсынады:

- `docker-compose up`: қолданбаны іске қосады және `docker-compose.yml` файлына негізделген контейнерлерді жасайды.
- `docker-compose down`: қолданба үшін жасалған барлық контейнерлерді тоқтатады және жояды.
- `docker-compose ps`: Docker Compose көмегімен жұмыс істейтін контейнерлердің күйін көрсетеді.
- `docker-compose logs`: контейнер журналдарын көруге мүмкіндік береді.
- `docker-compose exec`: Контейнер ішіндегі командаларды орындауға мүмкіндік береді, мысалы: `docker-compose exec` қызмет командасы.

`Docker-compose.yml` файлдарын жасау және Docker Compose көмегімен көп контейнерлік қолданбаларды басқару контейнерлерді орналастыру мен басқаруды ыңғайлы және тиімді етеді. Бұл әзірлеушілер мен операторларға күрделі микросервис қолданбаларын ең аз күш жұмсап оңай конфигурациялауға және іске қосуға мүмкіндік береді.

Docker қолданбаларды жинақтауға, орналастыруға және басқаруға арналған кешенді құралдарды ұсынады, бұл оны заманауи программалық қамтаманы әзірлеу және тестілеу үдерісі үшін маңызды етеді. Бұл технология дамудың әртүрлі аспектілерінде айтарлықтай артықшылықтар береді.

Біріншіден, Docker ортаның портативтілігіне кепілдік береді. Қолданбаны және оның барлық тәуелділіктерін қамтитын контейнерлерді жасау арқылы әзірлеушілер қолданбаның Docker орнатылған барлық орталарда бірдей әрекет етуін қамтамасыз етеді. Бұл жүйе конфигурацияларындағы айырмашылықтармен байланысты мәселелерді жояды, бұл әсіресе бөлінген топтарда және әзірлеуден өндіріске көшу кезінде маңызды.

Екіншіден, Docker тәуелділікті оқшаулауды қамтамасыз етеді. Docker контейнерлері нұсқалардың қайшылықтарын болдырмайтын және тәуелділікті басқаруды жеңілдететін барлық қажетті кітапханалар мен тәуелділіктерді қамтиды. Бұл әсіресе көптеген микросервистері бар жобаларда және әртүрлі компоненттер кітапханалардың әртүрлі нұсқаларын қажет ететін белсенді әзірлеу орталарында маңызды.

Үшінші негізгі аспект – «даму ортасы код ретінде» тұжырымдамасы. Dockerfile файлын пайдалану әзірлеушілерге оны репликациялауға және автоматтандыруға мүмкіндік беретін кодта әзірлеу ортасын сипаттауға мүмкіндік береді. Бұл жаңа әзірлеушілер үшін ортаны орнату процесін жылдамдатады және әзірлеу ортасын жаңартуды жеңілдетеді.

Төртінші аспект – оқшауланған орталарда тестілеу. Docker негізгі жүйеден және басқа контейнерлерден оқшауланған контейнерлерде тестілеуді орындауға мүмкіндік береді. Бұл тестілеудің дәлдігі мен қайталануын жақсартады және отладка мен ақауды анықтауды жеңілдетеді, себебі әрбір сынақ ортасы толығымен басқарылады және болжауға болады.

Бесінші аспект - орналастыруды жеңілдету. Docker қолданбалардың өмірлік циклінің барлық кезеңдерінде қолдану процесін айтарлықтай жеңілдетеді. Әзірлеуші машиналарға жергілікті орналастыру стандартты және оңай қайталанатын процеске айналуға. Docker Compose пайдалану көп контейнерлік қосымшалардың құрылымын анықтауға және оларды бір пәрменмен іске қосуды басқаруға мүмкіндік береді, бұл қателерді азайтады және әзірлеуді жылдамдатады.

Алтыншы аспект бұлтты орналастыруға қатысты. Docker AWS, Azure және Google Cloud сияқты әртүрлі бұлттық платформаларда контейнерлерді орналастыруды жеңілдетеді. Бұл бұлтты ресурстарды тиімді пайдалануға және өзгертін жұмыс жүктемелеріне тез бейімделуге мүмкіндік беретін икемділік пен ауқымдылықты қамтамасыз етеді.

Жетінші аспект – микросервистерді контейнерлеу. Docker микросервис архитектурасы үшін өте қолайлы, бұл әрбір микросервисті өз контейнеріне жинауға мүмкіндік береді. Бұл микросервистің тәуелсіздігі мен даму икемділігін қамтамасыз ете отырып, олардың масштабтауын, орналастыруын және басқаруын жеңілдетеді.

Сегізінші аспект – әзірлеу мен тестілеуді жеделдету. Docker ортаны орнату уақытын қысқартады, CI/CD процестерін жылдамдатады және қосымшаның әртүрлі нұсқаларын қатарлас әзірлеуге және тексеруге мүмкіндік береді. Бұл команданың жалпы өнімділігін арттырады және нарыққа шығу уақытын жылдамдатады.

Жалпы алғанда, Docker қолданбаларды әзірлеу мен тестілеуде сенімділікті, икемділікті және болжамдылықты қамтамасыз етеді. Оны пайдалану уақыт пен ресурс шығындарын қысқартуға, программалық қамтама сапасын арттыруға және әзірлеу, тестілеу және операциялық топтар арасындағы ынтымақтастықты жақсартуға әкеледі.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Новик И. П. Оркестрация Docker контейнеров: концепция Zero Downtime Deployment. – 2020.
2. Белодед Н. И., Демиденко К. Г. Развитие и применение технологии контейнеризации в разработке программного обеспечения //Актуальные проблемы научных исследований: теоретические. – 2023. – С. 57.
3. Адаев Р. Б., Монахов В. И. Возможности контейнеризации для развертывания веб-приложений //Молодой учёный 3. – 2023. – С. 51