



INTERNATIONAL
SCIENCE REVIEWS



№ 1 (4) 2023

Natural Sciences and
Technologies series



INTERNATIONAL SCIENCE REVIEWS

Natural Sciences and Technologies series

Has been published since 2020

№1 (4) 2023

Astana

EDITOR-IN-CHIEF:

Doctor of Physical and Mathematical Sciences, Academician of NAS RK, Professor
Kalimoldayev M. N.

DEPUTY EDITOR-IN-CHIEF:

Doctor of Biological Sciences, Professor
Myrzagaliyeva A. B.

EDITORIAL BOARD:

- | | |
|----------------------------|--|
| Akiyanova F. Zh. | - Doctor of Geographical Sciences, Professor (Kazakhstan) |
| Seitkan A. | - PhD, (Kazakhstan) |
| Baysholanov S. S | - Candidate of Geographical Sciences, Associate professor (Kazakhstan) |
| Zayadan B. K. | - Doctor of Biological Sciences, Professor (Kazakhstan) |
| Salnikov V. G. | - Doctor of Geographical Sciences, Professor (Kazakhstan) |
| Mukanova A.S. | - PhD, (Kazakhstan) |
| Tasbolatuly N. | - PhD, (Kazakhstan) |
| Abdildayeva A. A. | - PhD, (Kazakhstan) |
| Chlachula J. | - Professor, Adam Mickiewicz University (Poland) |
| Redfern S.A.T. | - PhD, Professor, (Singapore) |
| Cheryomushkina V.A. | - Doctor of Biological Sciences, Professor (Russia) |
| Bazarnova N. G. | - Doctor Chemical Sciences, Professor (Russia) |
| Mohamed Othman | - Dr. Professor (Malaysia) |
| Sherzod Turaev | - Dr. Associate Professor (United Arab Emirates) |

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

Е.М.Олейникова, О.М.Кольцова, Е.З.Матеев, С.З.Матеева, А.Е.Матеева, М.М.Мирсаидов	ФЕНОЛОГИЯ, ПРОДУКТИВНОСТЬ И УРОЖАЙНОСТЬ <i>CARTHAMUS TINCTORIUS</i> L. ПРИ ВЫРАЩИВАНИИ В ЦЕНТРАЛЬНО-ЧЕРНОЗЕМНОМ РЕГИОНЕ РОССИИ И В СРЕДНЕЙ АЗИИ	5
М.О.Кенжеғұл	УЧАСТИЯ ШКОЛЬНИКОВ СТАРШИХ КЛАССОВ В ПРЕДМЕТНОЙ ОЛИМПИАДЕ ПО БИОЛОГИИ КАК ОСНОВА ВЛИЯНИЯ НА ВЫБОР БУДУЩЕЙ ПРОФЕССИИ	14
Н. Турмаханова	ИНТЕРАКТИВТИ ТАПСЫРМАЛАР – ЗЕЙІНДІ ҰСТАУДЫҢ БАСТЫ КЕПЛІ	20
Р.Смадинов	МЕТОДЫ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ ДЛЯ ОПРЕДЕЛЕНИЯ ТРЕНДОВ	26
А.Н. Құмарова, Б. Ж.Ергеш	ОБЗОР МЕТОДОВ И ТЕХНОЛОГИИ РАЗРАБОТКИ ЭЛЕКТРОННЫХ ОБРАЗОВАТЕЛЬНЫХ РЕСУРСОВ ДЛЯ ОНЛАЙН ОБУЧЕНИЯ.....	35
Zh.M.Seksenova, L.T.Kusseпова	RESEARCHING CLOUD TECHNOLOGIES AND ENSURING THEIR SECURITY.....	45
Zh.T.Abdullayeva, Zh.M.Seksenova	MODERN METHODS OF DATA ANALYSIS.....	56
Н.А.Оралбекова	ТҮРКІСТАН ОБЛЫСЫНЫҢ БИОКЛИМАТТЫҚ ЖАҒДАЙЫН БАҒАЛАУ.....	66
С.Оңталапұлы, Н.Тасболатұлы, Г.Ш.Омаркулова	АҚПАРАТТЫҚ ҚАУІПСІЗДІК ТӘУЕКЕЛДІГІН БАҒАЛАУДЫҢ ӘДІСТЕРІ МЕН ПРОГРАММАЛАРЫН ТАЛДАУ.....	78

ФЕНОЛОГИЯ, ПРОДУКТИВНОСТЬ И УРОЖАЙНОСТЬ *CARTHAMUS TINCTORIUS* L. ПРИ ВЫРАЩИВАНИИ В ЦЕНТРАЛЬНО-ЧЕРНОЗЕМНОМ РЕГИОНЕ РОССИИ И В СРЕДНЕЙ АЗИИ

Олейникова¹ Е.М., Кольцова¹ О.М., Матеев² Е.З., Матеева³ С.З., Матеева⁴ А.Е.,
Мирсаидов¹ М.М.

¹Воронежский государственный аграрный университет им. императора Петра I,
г. Воронеж, Россия, e-mail: cichor@agronomy.vsau.ru

²Воронежский государственный университет инженерных технологий,
г. Воронеж, Россия

³Таразский государственный университет им. М.Х.Дулати,
г. Тараз, Республика Казахстан

⁴Казахский национальный университет имени аль-Фараби,
г. Алматы, Республика Казахстан

Аннотация. Рассмотрены особенности ритма сезонного развития и семенной продуктивности сафлора красильного (*Carthamus tinctorius* L.) в регионах, значительно удаленных географических и резко различающихся по экологическим и климатическим условиям – Средней Азии (Республика Таджикистан, Согдийская область; Республика Казахстан, Жамбылская область) и Центральном-Черноземном регионе (ЦЧР) Российской Федерации (Воронежская область). Фенологические наблюдения за особями *C. tinctorius* в различных географических условиях позволили выявить значительное различие в сроках наступления фенофаз, что обусловлено разными сроками посева культуры и климатическими особенностями регионов. Сравнительный анализ семенной продуктивности сафлора красильного выявил, что значение основных показателей, формирующих урожай – потенциальной и реальной семенной продуктивности, коэффициента семенификации и массы образовавшихся семян характеризуется постоянством и мало зависит от географических условий. По результатам трехлетних полевых опытов можно предположить, что урожайность сафлора красильного при выращивании в промышленных масштабах в Воронежской области будет сопоставима с урожайностью в более южных регионах Средней Азии и Казахстана, в которых сафлор красильный выращивают в настоящее время.

Ключевые слова: *Carthamus tinctorius* L, ритм сезонного развития, потенциальная и реальная семенная продуктивность, фенологические наблюдения, интродукция, агроценозы.

ВВЕДЕНИЕ

В последние десятилетия наметилась устойчивая тенденция потепления климата, выражающаяся в увеличении среднегодовой температуры и снижении количества осадков. Сельскохозяйственное производство является той отраслью, которая должна опережающими темпами реагировать на подобные глобальные вызовы, поскольку обеспечение населения продуктами питания напрямую влияет на важнейшие социально-экономические аспекты жизни современного общества. Полагаем, что именно расширение ресурсной базы той или иной территории за счет интродукции устойчивых к климатическим изменениям культур способствует повышению продовольственной безопасности отдельных регионов и государства в целом.

Одной из основных задач исследований, связанных с интродукцией растений в качестве сырьевого ресурса для пищевой промышленности и сельского хозяйства, является правильный, научно обоснованный выбор потенциальных интродуцентов, что позволяет расширить ареал распространения и возделывания культурной флоры [2]. Этому предшествует большая исследовательская работа по изучению экологии и биологии потенциальных видов-интродуцентов, на основании которой можно сделать вывод о целесообразности использования того или иного вида растения для интродукционной работы.

В этом отношении определенный интерес представляет *Carthamus tinctorius* L. – сельскохозяйственная культура из семейства Asteraceae. Сафлор является масличной культурой и имеет широкий диапазон использования – как сырье для питания человека и производства корма животным, а также в медицине, парфюмерии и промышленности. При переработке сафлор служит источником не только растительного масла, но и полноценного белка [4,16,17]. Сафлор традиционно возделывается в засушливых регионах, однако его выращивание в Поволжье и других регионах России [3,14] показывает на возможность полноценного использования данной культуры для сельскохозяйственного производства в умеренных широтах.

Цель данной работы – провести сравнительный анализ ритма сезонного развития и семенной продуктивности *Carthamus tinctorius* при выращивании в разных эколого-климатических условиях.

МАТЕРИАЛЫ И МЕТОДЫ

Полевые исследования проведены в течение вегетационных сезонов 2019-21 гг. в Центрально-Черноземном регионе России и двух регионах Средней Азии: ботаническом саду Воронежского ГАУ (г. Воронеж, Россия), крестьянском хозяйстве «Кунар» (Жамбылская область, Жувалинский район, с. Карасу, Республика Казахстан) и дехканском хозяйстве имени Д. Холматова (Согдийская область,

Гафуровский район, Республика Таджикистан). Расстояние между географическими точками составило: между Воронежем и Худжантом – 3 222 км, между Воронежем и Таразом – 3 101 км, между Худжантом и Таразом – 466 км.

Объектами исследования являлись растения *Carthamus tinctorius* сорта Иркас [18], который районирован в южных регионах Казахстана. Поскольку в работе проводился сравнительный анализ ритма сезонного развития и семенной продуктивности сафлора, считаем целесообразным использование одного сорта во всех географических точках исследования (в том числе и ЦЧР России) для получения репрезентативных данных.

В качестве методической основы работы использованы традиционные методики фенологических наблюдений [2] и определения семенной продуктивности [1].

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Фенологическое развитие растений является внешним выражением процессов побегообразования в течение вегетационного сезона, поэтому его также называют ритмом или ритмикой сезонного развития. Ритм сезонного развития – видовая особенность растений, отражающая историю формирования вида в определенных метеорологических, почвенно-климатических и фитоценологических условиях через адаптивные изменения организма и отбор на видовом и популяционном уровне. Важнейшие признаки годичного роста и развития растения обусловлены внутренними закономерностями, то есть закономерностями организменного уровня [2,12,15].

Фенологические наблюдения за развитием сафлора красильного осуществлялись в 2019 году. Отметим, что значительные эколого-климатические различия районов исследования существенно корректировали график проведения сельскохозяйственных работ и наблюдений за растениями (табл.1).

Посев семян в Согдийской области провели 25 марта, в Жамбылской области – 20 апреля, в Воронежской области – 7 мая. Появление всходов и первого настоящего листа отмечено в Согдийской области провели 4 и 11 апреля, Жамбылской области – 30 апреля и 7 мая, в Воронежской области – 19 и 26 мая. Фазы бутонизации и начала цветения наблюдались в Согдийской области 22 мая и 7 июня, в Жамбылской области – 9 июня и 4 июля, в Воронежской области – 2 июля и 25 июля.

Сафлор красильный – монокарпический однолетник [7, 8, 18], поэтому после окончания цветения следует созревание семян, которое сопровождается общим засыханием растения. К моменту полного созревания семян приурочено и окончание онтогенеза вида, так как растение полностью засыхает.

Таблица 1. Сроки наступления фенофаз сафлора

Фенофазы	Согдийская область	Жамбылская область	Воронежская область
Посев	25.03.2019 г.	20.04.2019 г.	07.05.2019 г.
Появление всходов	04.04.2019 г.	30.04.2019 г.	19.05.2019 г.
Появление первого настоящего листа	11.04.2019 г.	07.05.2019 г.	26.05.2019 г.
Бутонизация	22.05.2019 г.	09.06.2019 г.	02.07.2019 г.
Начало цветения	07.06.2019 г.	04.07.2019 г.	25.07.2019 г.
Окончание цветения	29.06.2019 г.	09.08.2019 г.	19.08.2019 г.
Созревание семян/засыхание	15.08.2019 г.	11.09.2019 г.	09.09.2019 г.
Вегетационный период, дней	133 дней	135 дней	123 дня

Окончание цветения и полное созревание семян отмечено в Согдийской области 19 июня и 15 августа, Жамбылской области – 9 августа и 11 сентября, в Воронежской области – 19 августа и 9 сентября. Таким образом, нами получены интересные данные по продолжительности вегетационного периода – при выращивании в условиях короткого дня развитие культуры происходит за 133-135 дней, при увеличении продолжительности дня вегетация сокращается до 123 дней.

В литературе имеются данные [10], что в Пензенской области, расположенной к северо-востоку от Воронежской, продолжительность вегетационного периода сафлора красильного составляет 110-118 дней. Вероятно, так проявляется адаптационный механизм вида – при изменении внешних условий особи стремятся как можно быстрее сформировать семена и завершить цикл развития. Одновременно это служит доказательством пластичности культуры и возможности ее культивирования в разных географических и экологических условиях.

Семенная продуктивность является одним из важных показателей адаптации и степени соответствия экологических условий современных местообитаний биологическим требованиям вида. Семенная продуктивность конкретного вида характеризуется количеством семян, которые образуются на особи. Количество производимых видом семян может служить основным показателем его жизнеспособности в конкретных условиях обитания.

Семянки сафлора имеют белую или светло-бурую окраску, по форме обратно-яйцевидные, четырехгранные, сдавленные с боков, с прямоусеченной вершиной и расположенным по центру остатком столбика. Летучка беловато-бурая, закреплена слабо, состоит из достаточно длинных (до 10-12 мм) слабозазубренных щетинок. Семянки панцирные, панцирный слой глубоко погружен в ткани оболочки. Длина без летучки 6-9 мм, ширина в верхней части – до 5 мм (рис.1). Вес 100 семян – 3-5 г. [7,8].

Давно известно, что лишь часть закладывающихся на растении семян преобразуется в зрелые семена. Поэтому было предложено [1] понятие “семенная продуктивность” разделить на два: потенциальную семенную продуктивность (ПСП), под которой следует понимать количество семян и реальную семенную продуктивность (РСП), которая бы обозначала количество семян. Процентное соотношение между этими показателями (коэффициент семенификации) является показателем степени соответствия биологических свойств вида окружающим условиям обитания. Чем меньше этот коэффициент, тем в более жестких и неблагоприятных условиях находится популяция.

Семенная продуктивность сафлора красильного определяется числом корзинок на генеративном побеге (которое, в свою очередь, варьирует в зависимости от высоты побега и количества боковых побегов 1-2 порядка) и числом семян в корзинке. Нами установлено, что на побегах сафлора в разных географических условиях насчитывалось в среднем от 12 до 18 корзинок, в которых формировалось в среднем 23-26 семян.



Рисунок 1. Общий вид семян сафлора

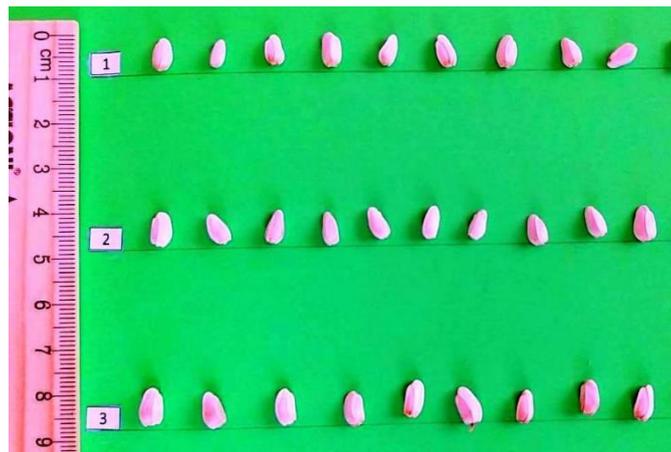


Рисунок 2. Семянки, выращенные в разных регионах: 1 – Согдийская обл.; 2 – Жамбылская обл.; 3 – Воронежская обл.

По данным многих исследователей [11,13], число семян является величиной относительно постоянной для вида, не зависящей от условий местообитания и мало изменяющейся по годам. Анализ полученных данных подтвердил это положение и для сафлора красильного. Установлено, что соотношения семян и семян в соцветиях особей сафлора, выращенных в различных географических условиях, практически не отличается (табл. 2). Более того, абсолютные значения этих показателей для Воронежской области выше, чем для областей Средней Азии, а коэффициент семенификации выше, чем для

засушливой Жамбылской области. Масса 100 семян также оказалась маловариабельной величиной и составила 3,5-4 г. для всех регионов исследования (табл. 2, рис. 2).

Нами также определена лабораторная всхожесть семян, созревших в разных областях. Исследование проведено весной 2020 года с сеянками, полученными в прошлом вегетационном сезоне (табл. 3). Установлено, что через 6 месяцев после уборки, сеянки сафлора красильного имеют высокие показатели энергии прорастания – 77-84% и всхожести – 91-93 %.

Таблица 2. Число семяпочек и семян на соцветие у *Carthamus tinctorius*

Согдийская область		Жамбылская область		Воронежская область	
Число СП ¹	Число СМ ²	Число СП	Число СМ	Число СП	Число СМ
31,38± 1,97	24,22± 1,57	30,46±2,33	23,11± 0,89	33,21± 2,39	25,26± 1,14
Коэффициент семенификации, %					
77,19		75,86		76,06	
Средняя масса 100 СМ, г					
3,66±0,27		3,61±0,34		3,53±0,18	

Высокие показатели энергии прорастания и всхожести семян сафлора, выращенных в Воронежской области, указывают на то, что они смогли полностью сформироваться в условиях климата Центрально-Черноземного региона и в дальнейшем прорастут в полноценные растения.

Таблица 3. Лабораторная всхожесть семян *Carthamus tinctorius*

Согдийская область		Жамбылская область		Воронежская область	
1 ³	2 ⁴	1 ³	2 ⁴	1 ³	2 ⁴
78,25± 1,49	92,50± 2,32	84,75± 2,33	93,25± 2,01	77,50± 2,39	91,75± 1,14

В развитие данных исследований было решено провести сравнительный анализ семенной продуктивности и урожайности нескольких сортов сафлора, районированных для южного Казахстана. Кроме уже известного сорта Иркас, были использованы сорта Акмай и Центр 70. Работы проведены в 2021 году в условиях стационарного опыта, заложенного на территории ботанического сада им.

¹ СП – семяпочек.

² СМ – семян.

³ 1 – энергия прорастания, %

⁴ 2 – всхожесть, %

Келлера, входящего в комплекс УНТЦ «Агротехнология» Воронежского ГАУ. Мелкоделяночный опыт заложен в трехкратной повторности, площадь делянки 10 м². Расположение делянок очередное. Семянки сафлора высевали в рядки с расстоянием между ними 40 см, семянки в рядке располагали на расстоянии 20 см, т.е. технология возделывания аналогична подсолнечнику. На каждой делянке опыта, таким образом, располагалось 10 рядков культуры. Семянки для посева были откалиброваны, лабораторная всхожесть составила 98-100%. Посев культуры провели 12 мая 2021 г., после прогревания почвы до 10⁰ С. Все работы в опыте проводились вручную.

Почва опытного участка – чернозем выщелоченный среднеспособный малогумусный тяжелосуглинистый со следующими показателями плодородия: рН сол. – 5,2-5,4; гидролитическая кислотность 3,20-3,35 мг-экв/100 г почвы, сумма поглощенных оснований около 25 мг-экв/100 г почвы с преобладанием кальция, степень насыщенности основаниями около 88%, содержание гумуса – 3,7-3,8%. Обеспеченность почвы элементами минерального питания для фосфора повышенная – около 105 мг/ на кг почвы и калия высокая – 120 и более мг/ на кг почвы [3, 5].

Как указывалось выше, все сорта являются сортами казахской селекции. Поэтому они засухоустойчивы, не требовательны к условиям почвенного питания. Тогда как в условиях Черноземья, этот показатель должен позволить получать высокие урожаи сафлора.

Фенологические наблюдения за развитием культуры показали, что первые всходы появились 23 мая 2021 г., а уже через три дня наблюдали полное прорастание семян в рядках. Всходы всех сортов были дружными и хорошо развивались. Как и подсолнечник на первых этапах развития, культура очень чувствительна к сорнякам, поэтому уже на стадии семядольных листьев была проведена первая прополка (26 мая), вторая и третья прополки проводились соответственно 21 июня и 19 июля. Уборка осуществлялась 14 сентября методом обрезания корзинок с последующим их ошелушиванием в лабораторных условиях.

Соответственно, вегетационный период для сафлора в условиях Центрального Черноземья в 2021 году составил 124 дня. Изучение морфологических признаков растений показало, что эти показатели были близки для всех изучаемых сортов: высота генеративных растений до 70 см, величина боковых побегов около 5 шт., общее количество листьев 35-40 шт., диаметр корня 1,3 см. Отличия проявлялись в количестве соцветий на растении. Так, минимальным оно было для сорта Иркас – 13, максимальным для сорта Центр 70 – до 20 шт. Отличалась и степень выполненности корзинок: для сорта Иркас она колебалась в интервале 2-15 семян, для сорта Акмай – 8-22 шт. и сорта Центр 70 достигало 25-30 шт. Именно этот показатель в конечном итоге сформировал и общий урожай культуры. Общая продуктивность по сортам составила: Иркас – 290 г/10м², Акмай –

358 и Центр 70 – 478. Полученные семянки обладают высокой энергией прорастания – до 80% и всхожестью до 92%, что не уступает семенам, полученным в Средней Азии, где эти показатели составили соответственно 78-80 и 93%, что со временем позволит сформировать собственный семенной материал высокого качества [9].

По показателю продуктивности для Центрального Черноземья наиболее перспективным является сорт Центр 70.

Таким образом, сравнительный анализ семенной продуктивности сафлора красильного выявил, что значение основных показателей, формирующих урожай – потенциальной и реальной семенной продуктивности, коэффициента сенификации и массы образовавшихся семянок – характеризуется постоянством и мало зависит от географических условий. Это позволяет нам предположить, что урожайность сафлора красильного при выращивании в промышленных масштабах в Воронежской области будет сопоставима с урожайностью в более южных регионах Средней Азии и Казахстана, в которых сафлор красильный выращивают и в настоящее время.

СПИСОК ЛИТЕРАТУРЫ

1. Вайнагий В.И. Методика статистической обработки материала по семенной продуктивности растений на примере *Potentilla burea* L. // Растительные ресурсы. – 1973. – Т. 9, № 2. – С. 287-296.
2. Гладышева О.В., Олейникова Е.М. Онтогенез и феноритмотипы пряно-ароматических интродуцентов в ЦЧР [Эл. ресурс]. – Воронеж: ВГАУ, 2016. – 198 с.
3. Житин Ю.И., Стекольников Н.В. Практические аспекты решения проблем экологической бионики // Вестник Воронежского ГАУ. – 2011. – №1 (28). – С. 18-20.
4. Картамышев В.Г., Шурупов В.Г., Картамышева Е.В., Костюк О.А. Изучение сафлора в Ростовской области // Вестник РАСХН. – 1997. – № 2. – С. 42-43.
5. Коноплина Е.А. Оценка воздействия вторичных ресурсов сахарного производства на биоресурсы агроэкосистем: автореф. дис. ... канд. с.-х. наук: 03.00.12. – Воронеж, 2011. – 20 с.
6. Норов М.С. Сафлор – перспективная кормовая культура в условиях богары Таджикистана // Кормопроизводство. – 2005, №11. – С. 17-18.
7. Олейникова Е.М., Кольцова О.М., Матеева С.З., Матеева А.Е., Мирсаидов М.М. Экологиялық және климаттық факторлардың *Carthamus tinctorius* L. дамуы мен өнімділігіне әсері // Ізденістер, Нәтижелер. – 2021. – № 3 (91). – С. 43-51.
8. Олейникова Е.М., Матеев Е.З., Матеева С.З., Мирсаидов М.М. Онтоморфогенез и ритм сезонного развития сафлора красильного (*Carthamus tinctorius* L.) при выращивании в различных географических условиях // Материалы X международной конференции по экологической морфологии растений, посвященной памяти И. Г. и Т. И. Серебряковых. – М.: МГПУ, 2019. –С. 197-201.
9. Олейникова Е.М., Кольцова О.М., Матеев Е.З., Матеева С.З., Матеева А.Е., Мирсаидов М.М. Особенности выращивания сафлора красильного (*Carthamus tinctorius* L.) в разных

- географических зонах (на примере Средней Азии и ЦЧР России) // Вестник Воронежского ГАУ. – 2021. – №14 (68). – С. 52-61
10. Прахова Т.Я., Кшникаткина А.Н., Щанин А.А. Агроэкологическое изучение сортов сафлора красильного в Пензенской области // Сурский вестник. – 2018. – № 2 (2). – С. 24-27.
 11. Работнов Т.А. Методы изучения семенного размножения травянистых растений в сообществах // Полевая геоботаника. – М., Л., 1960. – Т.2. – С. 20-40.
 12. Серебряков И.Г. Соотношение внутренних и внешних факторов в годичном ритме развития растений // Ботан. журнал. – 1966. – Т. 51, № 7. – С. 923-937.
 13. Скользнева Л.Н., Кирик А.И., Агафонов В.А. Популяционная экология растений. Практический курс. – Воронеж: Из-во ВГУ, 2003. – 120 с.
 14. Харисова А.В. Фармакогностическое исследование сафлора красильного (*Carthamus tinctorius* L.): автореф. дис... канд. фарм. наук. – Самара, 2014. – 24 с.
 15. Хмелев К.Ф., Никулин А.В., Олейникова Е.М. Сезонная и погодичная динамика численности и возрастного состава ценопопуляций *Cichorium intybus* L. в Русской лесостепи // Растительные ресурсы. – 2003. – Т. 39. № 1. – С. 3-11.
 16. Feng Z.M., He J., Jiang J.S., Chen Z. NMR solution structure study of the representative component hydroxysafflor yellow A and other quinochalcone C-glycosides from *Carthamus tinctorius* // J Nat Prod. – 2013. – Vol. 76, No. 2. – P. 270-274.
 17. Liu J.X., Guo Z., Li G., Yue J.W. Hyperspectral characteristics of *Carthamus tinctorius* in Xinjiang region // Zhongguo Zhong Yao Za Zhi. – 2013. – Vol. 38, No. 9. – P. 1335-1339.
 18. Oleynikova E. M., Koltsova O.M., Mateyeva S. Z., Mateyeva A. E. and Mirsaidov M. M. *Carthamus tinctorius* L. development and productivity under the influence of ecological and climatic factors // IOP Conf. Series: Earth and Environmental Science. – 2021. – Vol. 723. – № 020282. DOI: 10.1088/1755-1315/723/2/022082.

УЧАСТИЯ ШКОЛЬНИКОВ СТАРШИХ КЛАССОВ В ПРЕДМЕТНОЙ ОЛИМПИАДЕ ПО БИОЛОГИИ КАК ОСНОВА ВЛИЯНИЯ НА ВЫБОР БУДУЩЕЙ ПРОФЕССИИ

М.О.Кенжегүл

Международный университет Астана, магистрант 2 курса, Астана, Казахстан.

E.mail: manshuk.kenzhegul@mail.ru

Аннотация: Известно, что участие старшеклассников в олимпиадах по естествознанию влияет на их отношение к науке, и такой опыт повышает их интерес к науке. Однако меньше известно о том, как участие в научных олимпиадах влияет на выбор будущей профессии. В этом исследовании мы стремились выяснить, как участники Казахской олимпиады по биологии воспринимают свой опыт участия в этом конкурсе, как этот опыт меняет их отношение к биологии и влияет ли он и как он влияет на их выбор будущей профессии. Чтобы ответить на эти вопросы, мы собрали данные 5 прошедших участников городского тура олимпиады по биологии с помощью интервью. Что касается их личного опыта участия в олимпиаде по биологии, ученики подчеркнули важность своего научного прогресса, понимание методов исследования, знакомство с другими учениками с такими же интересами и контакт с академической средой. Они часто упоминали контраст между школьной биологией и биологией, представленной на олимпиаде по биологии. Участие обычно углубляло их интерес к биологии или приводило к более высокой специализации в этой области. Как ученики, решившие продолжить свою профессию в области биологии, так и те, кто этого не сделал, подчеркивали важность опыта участия в олимпиаде по биологии, хотя в некоторых случаях этот опыт приводил к выбору другой области будущей учебы. Однако ученики, которые не продолжили профессию в области биологии, обычно обращались в другие области науки, такие как физика или медицина. Наше исследование дает важные сведения о процессе выбора будущей профессии для талантливых и ориентированных на биологию старшеклассников и может иметь важные последствия как для преподавания биологии, так и для организации других научных олимпиад.

Ключевые слова: олимпиада по биологии, отношение к биологии, выбор будущей профессии, старшеклассник.

1. ВВЕДЕНИЕ

С раннего детства дети проявляют любознательность и интерес к живому миру, наблюдают за ним и задают вопросы. Однако такой интерес имеет тенденцию к снижению с возрастом. В подростковом возрасте дети могут легко потерять интерес к природе, если не будут подвергаться дальнейшим мотивационным воздействиям. Внеклассные мероприятия, такие как курсы свободного времени, летние лагеря или предметные олимпиады, могут играть важную роль в углублении интересов учащихся и влиять на выбор ими дальнейшей профессии.

В последние годы значительно сократилось количество студентов, изучающих естественные науки. Это снижение представляет собой довольно серьезную проблему, поскольку исследования в области естественных наук являются одним из условий экономического, социального и культурного прогресса. Поэтому поддержка интереса учащихся к естественным наукам имеет большое значение. Одним из источников такой мотивации являются внеклассные мероприятия, например предметные олимпиады.

Биологическая олимпиада — предметное соревнование, проводимое в Казахстане с 1990 года. Основная цель олимпиады — выявление, поддержка и развитие интереса одаренных учащихся к биологии. Олимпиада по биологии это не только конкурс: с ним связаны и другие мероприятия, такие как летние лагеря, где студенты могут посещать множество лекций и участвовать в практических заданиях.

Это исследование направлено на качественное изучение опыта прошлых участников олимпиады по биологии и оценку того, повлияло ли и как участие в олимпиаде на отношение учащихся к биологии и их выбор дальнейшего обучения. Исследование направлено на то, чтобы ответить на следующие исследовательские вопросы: Как участники Казахстанской олимпиады по биологии воспринимают свой опыт участия в этом соревновании? Как участие в олимпиаде по биологии меняет отношение участников к биологии? Как опыт олимпиады по биологии влияет на выбор будущей профессии участниками?

2 МЕТОДЫ

Основная цель этого исследования состояла в том, чтобы изучить мнения и опыт старшеклассников об олимпиаде по биологии. Поскольку нас очень интересовало, как они индивидуально воспринимают свое участие, мы использовали качественный подход для изучения поставленных вопросов.

2.1 Респонденты

Во-первых, мы искали потенциальных респондентов среди бывших участников олимпиады по биологии по следующим критериям: минимум одно участие в городском туре олимпиады по биологии и участие в олимпиаде по биологии в 2020 году или позже. Эти критерии позволили сделать выборку более однородной по вовлеченности учащихся в олимпиаду (участвовали только учащиеся с определенным уровнем успеваемости) и возрасту респондентов. Следуя этим критериям, мы напрямую попросили нескольких бывших участников взять интервью. Двое из них, которые согласились с интервью, предоставили нам контакты других прошлых участников, и в итоге получилось 5 респондентов.

2.2 Сбор данных

Все интервью проводились в тихих общественных местах, таких как рестораны и библиотеки. В самом начале респондентам разъяснялась цель и примерная структура интервью. Им также было предложено задать любые вопросы об исследовании. Интервью было сосредоточено на нескольких областях: происхождение отношения респондентов к биологии, их опыт и отношение к олимпиаде по биологии, их отношение к биологии как школьному предмету и ее отношение к биологии как представленны на олимпиаде по биологии и влияние участия в олимпиаде на выбор будущей профессии.

Имена всех респондентов, а также все другие данные, которые могли привести к их идентификации, были изменены.

3 ОСНОВНАЯ ЧАСТЬ

3.1 Опыт олимпиады по биологии

Было несколько тем, которые возникли в связи с личным опытом: респонденты упомянули важность социальных аспектов соревнований, улучшение собственных знаний и навыков, влияние на их амбиции, удовлетворение от достижений и чувства, связанные с конкурентной средой.

Социальные взаимодействия были одной из самых обсуждаемых тем. Эта тема касалась не только летнего лагеря, организованного для наиболее успешных участников олимпиады по биологии, но и национального этапа конкурса. Респонденты говорили о завязывании новых дружеских отношений, им очень нравилось дружелюбное отношение лекторов и приятная атмосфера в целом. Прилагательные, связанные с их описанием людей, которых они встретили на Олимпиаде, были «хорошие», «отличные» или «приятные». Для многих респондентов олимпиада по биологии стала первой возможностью познакомиться с другими учащимися с такими же интересами и энтузиазмом в отношении биологии. Это заставляло их чувствовать себя частью группы, особенно в отличие от их предыдущего школьного опыта.

Участники также высоко оценили академические преимущества, которые они получили от олимпиады. Они говорили не только о новой и интересной информации или практических занятиях, но и о способе представления новых фактов (близко к обучению, основанному на исследованиях). Трое участников также заявили, что именно олимпиада дала им представление о работе ученых и науке в целом. Они также выразили свое удивление тем, что «наука может быть чем-то таким интересным и увлекательным». Участие в олимпиаде по биологии дало студентам чувство достижения и удовлетворения от решения конкурсных заданий. Более того, ощущение успеха и знаний работало для них как фактор мотивации учиться дальше и стараться еще усерднее.

3.2 Олимпиада по биологии и ее влияние на отношение школьников к биологии

При описании своего отношения к биологии до участия в олимпиаде по биологии респонденты обычно различали биологию как школьный предмет и «живой мир». Если их отношение к живому миру в целом было положительным, они имели много увлечений, связанных с биологией, с удовольствием читали биологические книги и энциклопедии или смотрели документальные фильмы по телевидению, то их отношение к биологии как школьному предмету было гораздо более сложным. Во-первых, это сильно зависело от их учителя биологии — он или она могли влиять на отношение учеников к биологии как положительно, так и отрицательно. Во-вторых, на их отношение также влияло содержание школьных занятий. Респонденты критиковали отсутствие информации или традиционный способ обучения, основанный на заметках из презентации учителя. Однако в случае отрицательного отношения к учителю или биологии как школьному предмету глубокий интерес к этой области заставлял многих респондентов компенсировать недостаток информации в школе самостоятельным изучением.

3.3 Влияние на выбор профессии

Многие респонденты почувствовали влияние участия в олимпиаде при выборе будущей профессии. Однако сила воздействия у них была разной. Интервью выявили три основных источника этого влияния. Во-первых, олимпиада по биологии дала участникам ощущение работы ученых. Респонденты заявили, что до участия в олимпиаде по биологии и знакомства с преподавателями вузов у них не было или было совсем другое представление о том, что такое наука и чем занимаются ученые.

3.4 Значение для практики

Наше исследование показывает, что одаренные учащиеся, проявляющие интерес к биологии, нуждаются в других внеклассных мероприятиях, таких как научные конкурсы, для развития своих талантов и углубления интереса к этой области. Им также полезно встречаться со сверстниками с теми же интересами, а также встречаться с людьми, уже работающими в области биологических исследований.

Поэтому первым шагом учителей биологии является выявление таких одаренных учащихся. Существует множество методов выявления одаренных учащихся среди их сверстников. Однако мы хотели бы выделить важность наблюдения учителя. Все респонденты нашего исследования проявляли глубокий интерес к биологии, поскольку они могли помнить: они продолжали задавать вопросы на уроках биологии и проявляли интерес к живому миру. В ряде случаев одной из возможных проблем при выявлении одаренных учащихся могла быть их

разносторонность: большинство респондентов нашего исследования заявили, что участвовали во всевозможных конкурсах и олимпиадах и при этом добились очень хороших результатов.

Очевидно, что выявление таких одаренных учащихся имеет смысл в том случае, если школа может предоставить возможности для дальнейшего развития талантов учащихся. Одной из возможностей является включение обучения на основе запросов или других методов, которые приводят к менее структурированным урокам, основанным в большей степени на обсуждениях со студентами и их собственной деятельности. Важность поддержки учащихся в их интересы имеют решающее значение, особенно в подростковом возрасте, поскольку их интересы могут исчезнуть в этом возрасте без внешних стимулов. Поддержка со стороны родителей учащихся также очень важна. Поэтому педагог должен информировать и родителей о дальнейших возможностях развития таланта их ребенка.

4. ВЫВОД

Наше исследование показывает, что опыт олимпиады по биологии меняет отношение участников к биологии, а также влияет на их выбор дальнейшего обучения. Благодаря конкурсу респонденты углубили свой интерес к биологии, завели новые дружеские отношения с другими участниками и лекторами и получили опыт обучения на основе запросов. Все эти факторы повлияли на них и при выборе направления дальнейшего обучения.

Олимпиада по биологии – это не просто соревнование. Много лекций и практических заданий, связанных именно с национальным туром олимпиады по биологии. Эти мероприятия позволяют участникам получать образование, основанное на запросах, мотивируют их, развивают их навыки и знания и поддерживают их естественное любопытство. Учитывая тот факт, что большинство участников олимпиады по биологии являются одаренными учениками, а их интерес и знания, как правило, намного выше, чем у их сверстников, участие в олимпиаде часто является одной из немногих возможностей для развития своих талантов.

Большое значение имеет также контакт с другими студентами, интересующимися теми же интересами, а также с преподавателями. У участников есть возможность поделиться своей страстью к биологии со своими сверстниками, чего они раньше не испытывали и что их очень мотивирует. Контакт с лекторами важен, особенно потому, что лекторами являются преподаватели или студенты университетов и обычно активно участвовать в биологических исследованиях. Таким образом, лекторы позволяют участникам познакомиться с методами исследования, а также служат моделями ученых. В результате участники часто меняют свои представления о будущей профессии и решают изучать биологию.

Олимпиада по биологии – одно из очень важных внеклассных мероприятий, которое может повлиять на отношение учащихся к биологии и их профессиональные предпочтения. Однако необходимо отметить, что таким мотивационным фактором может служить не только олимпиада по биологии, но и другие внеклассные мероприятия, такие как курсы биологии и летние лагеря. Более того, они поддерживают менее конкурентоспособных студентов, которые не получат столько пользы от олимпиады.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ:

1. «Актуальные проблемы общества в контексте научных исследований молодых учёных», (части 1,2), г. Астана, 2006 г.
2. Брук, Ю.И. К. Кикоин и олимпиады. Из истории школьных олимпиад в СССР // Заметки по еврейской истории. – 2008. – № 3 (94). – С.28-34.
3. Oliver, M., Venville, G. (2011). An Exploratory Case Study of Olympiad Students' Attitudes towards and Passion for Science. *Int. J. Sci. Educ.* 33(16), pp. 2295–2322.
4. Franz-Odendaal, T., Blotnicky, B., French, F., Joy, P. (2014). Career Choices and Influencers in Science, Technology, Engineering and Math: An Analysis of the Maritime Provinces. WISE Atlantic Survey Executive Report. NSERC Chair for Women in Science & Engineering.
5. Wirt, J. L. (2011). An analysis of Science Olympiad participants' perceptions regarding their experience with the science and engineering academic competition. Dissertation thesis. Seton Hall University.
6. Rocard, M. (2007). Science education now: A renewed pedagogy for the future of Europe, European Commission, Directorate-General for Research, Science, Economy and Society, Information and Communication Unit. Brussels: Office for Official Publications of the European Communities.
7. Schreiner, C., Sjøberg, S. (2004). The relevance of science education. Sowing the Seed of ROSE, *Oslo Acta Didact.* 4, pp. 5–120.

ИНТЕРАКТИВТІ ТАПСЫРМАЛАР – ЗЕЙІНДІ ҰСТАУДЫҢ БАСТЫ КЕПІЛІ

Н.Турмаханова

7M01503-Химия білім бағдарламасының магистранты, 2 курс

Астана Халықаралық университеті, Астана қаласы,

Қазақстан Республикасы

E-mail: nadira.turmahanova@gmail.com

87075696056

Аңдатпа. Ақпараттық технологиялар мен интернет дамыған заманда әрбір адамның зейінмен байланысты проблемалары бар. Миға күнделікті келіп жатқан ақпараттар легін толастату да мүмкін емес. Алайда, адамның миы ол ақпараттың бәрін қорытуға қауқарсыз. Күнделікті келіп түсетін мәліметтер әр түрлі тақырып пен форматты. Ми ойланып үлгермей жатқанда екінші бейне немесе афиша алдымызға шығады. Осының нәтижесінде, адамдарда клиптік ойлау жүйесі қалыптасып келіп жатыр. Ол дегеніміз ойлауымыздың қысқа ұзақтықтағы бейнелерден тұруы. Ақпарат 5-10 секундта ауысып отырмаса, зейін шашырап, ақпарат қабылдаудан жалығып, келесі ақпаратқа өтіп кетеді. Мұның барлығы, әрине, мектеп оқушыларының оқу процесіне қатты әсер етуде. Сабақ барысында білім алушылардың зейінін сабақта 45 минуттың 30-40 % -ында ғана ұстап отыруға болады. Осы тиімділікті арттыру үшін оқу процесіне интерактивті тапсырмаларды қосудың маңызы зор.

Кілт сөздер: клиптік ойлау, назар, интерактивті тапсырмалар, зейін, зейінді шоғырландыру.

КІРІСПЕ

Күннен-күнге заман қарыштап дамып, біз қабылдайтын ақпараттардың саны да сапасы да артып жатыр. Миға келетін ақпараттар легі тек ұйқы кезінде ғана толастайды. Одан басқа уақыттарда миымыз тоқтамастан жан-жақтан әртүрлі мағлұматтарды қабылдауда. Әрқайсысы әртүрлі формат пен тақырыпта. Мессенджерлер, теледидар, радио, ғаламтордағы жан-жағынан шығатын қалқымалы беттер, көшедегі жарнамалық баннерлер мен афишалар миымызға жан-жақтан шабуыл жасауда. Сонымен қатар, әр екі жыл сайын желідегі ақпарат көлемі екі есеге өсіп жатыр. Мұның барлығы біздің бір нәрсеге зейінімізді шоғырландыра алу қабілетімізді нашарлатуға айтарлықтай үлесін қосады.

Осыған байланысты Элвин Тоффлер «Клиптік ойлау» деген терминді ең алғаш рет қолданды және бұл термин қазір көп қолданысқа ие. Оның зерттеулері бойынша клиптік ойлау дегеніміз – адамның жаңа ақпаратты өте жарқын және қысқа бейнебаяндар арқылы қабылдау қабілеті. Кейбір ғалымдардың пайымдауынша, бұл тіпті ойлану деуге де келмейді. Адам ойланып үлгермей

жатқанда келесі ақпарат немесе клип шыға келеді. Соңғы зерттеулерге сүйенсек, қазіргі Z ұрпағының зейінді ұстай алу ұзақтығы 8 секундқа дейін қысқарған. Егер осы уақыт аралығында ақпарат ілінбесе, онда адам оны жіберіп алады және ұмытып кетуі мүмкін. Жастар кітаптар мен газеттерге қарағанда бейне ақпаратқа көбірек көңіл бөлетіні сондықтан. Адамдар теледидар бағдарламалары, интернет және бейне арқылы ақпарат алуды артығырақ көреді.

Ақпарат жеткізу көздерінің осылай қарқынды дамуының зиянды жақтары да бар. Ол ең алдымен - зейіннің шоғырлана алмауы. Зейіннің нашар болуы үлкендердің де балалардың да ең басты мәселесіне айналған. Бір орында отырып кітап оқу, қимылсыз бес минут отыра алу, бірсарынды дәрісті бес минут бойы тыңдай және осыған ұқсас іс-әрекеттер біраз адамдарға қиындық туғызады. [1]

ЗЕРТТЕУ ӘДІСТЕРІ

Білім саласына айтарлықтай әсер етіп жатқан факторлардың бірі де – білім алушылардың бір орында ұзақ отыра алмауы, сабаққа деген қызығушылығының жоқтығы және назарын жиі басқа жақтарға аударып әкетуі. Осыған байланысты ұстаздар әртүрлі жаңа әдіс-тәсілдерді қарастырып, қайтсек оқушының назарын аудара аламыз деп әлек. Өйткені әлемдік ақпарат құралдарымен де, өзгерістермен де күресуге шамамыз жетпесі анық. Қолымыздан келері – оқу процесін білім алушылардың ойлану және ақпаратты қабылдау ерекшелігіне қарай бейімдеу. Тақырыптың одан әрі ашылуы үшін Z және Альфа ұрпақтарының ақпаратты меңгеру ерекшеліктері мен олардың қажеттеліктерін қамтамасыз ету жолдары қарастырылды. Ол үшін осы жастағы жасөспірімдер мен балалардан алынған кері байланыс нәтижесінде осы оқушылардың дәстүрлі сабақ және интерактивті тапсырмаларға негізделген сабақ кездеріндегі зейінді ұстау ұзақтықтары салыстырылды.

Z және Альфа ұрпақтарына сабақты дәстүрлі форматта өткізу арқылы жаңа мәліметті беру біраз қиын. Бастапқы 5 минутта қабылдап отыруы мүмкін, бірақ одан кейін назар басқа жаққа ауа бастайды. Слайд арқылы түсіндіру арқылы да әрі кетсе ақпаратты визуалды түрде оңай қабылдайтын балаларға жеткізе алуымыз мүмкін. Көп балаларға міндетті түрде ұстап көру, әрі бері қимылдау, бейнеролик көру, анимациялық түрдегі ақпаратты берген жөн болады.

Осы орайда педагогикада 1960 жылдардан бастап таныла бастаған интерактивті тапсырмалардың орны ерекше. Бір-бірімен пікір алмасып, орындарынан қозғалып, миға шабуыл жасап және оқушылардың өздерінің тақырыпты өмірмен байланыстыруға тырысуы өте маңызды. Интерактивті тапсырмалар тек қана өткен тақырыпты бекітуге ғана емес, сондай-ақ жаңа мәліметті үйренуге де бағытталған. Педагогика қазір осы сынды тапсырмаларға бай: миға шабуыл, топтық талқылаулар, шығармашылық тапсырмалар, рөлдік ойындар, жұптық жұмыс, кейстар арқылы оқыту, дилемма шешу, жарыстар және

тағы басқа. Тиімді интерактивті тапсырмалардың артықшылықтары мен қолдану нәтижесінде білім алушылардың бойында қалыптасатын қабілеттер зерттелді. Тәжірибе жүзінде арнайы тақырыптар мен интерактивті тапсырмалар таңдалып, анализ жасалды.[2]

ЗЕРТТЕУ НӘТИЖЕЛЕРІ

Зерттеу нәтижесінде, бір сөзбен айтқанда, интерактивті тапсырмалар зейінді шоғырландырудың басты кепілі. Интерактивті тапсырмаларды қолдану білім алушыны дербес етеді, олар осы арқылы өмірге бейімделеді, әртүрлі жағдайларда бағдарлай алады. Білім алушының танымдық, шығармашылық дағдыларын, өз білімін өз бетінше құра білу, ақпараттық кеңістікте бағдарлай білу қабілеттерін дамытуға және сыни ойлауды, ақпараттық қызмет дағдыларын дамытуға ықпал етеді. Және ең бастысы, фокусты ұзақ білім алуда ұстап тұра алатын оңтайлы әдіс-тәсілдердің жиынтығы.

Интерактивті тапсырмалар мен жаттығулардың бір ерекшелігі-олар тек өткен материалды бекітуге ғана емес, жаңасын алуға да бағытталған. Интерактивті тапсырмалар шеңберінде жаңа оқу материалын алуды білім алушылар өз бетінше, мұғалімнің басқаруымен жүзеге асырады. Оқушылар жаңа мағлұматты өзі түсінуге тырысып, миын біраз қинайды. Ақпаратты өзі түсіне алатынына көзі жеткен баланың оқуға деген құлшынысы да ашыла түседі.

Орта мектептің 8-9 сынып оқушыларына химияны оқыту барысында интерактивті тапсырмаларды қолдану арқылы жаңа сабақ түсіндірілді. Нәтижесінде, 8 сыныптарда оқушылардың үлгерімі салыстырмалы түрде 1-тоқсаннан қарағанда 2-тоқсанда 30%-ға артқан.[3]

ТАЛҚЫЛАУ

Сабақ басталғаннан біткенге дейінгі әр қадамды интерактивтендіруге болады. Сабақтың тақырыбын тақтаға жай жазып немесе шығарып қою ешқандай қызығушылық тудырмауы мүмкін. Ал бірақ, тақырыпқа байланысты хикая айтып немесе бейнеролик көрсетіп сол арқылы тақырыптың қандай болатынын білім алушылардан сұраудың әсері мүлдем басқаша болары сөзсіз. Екіншісінде балалар: «Не болар екен?» деп өздігінен қызыға бастайды. Осылай басталған сабақты әрі қарай топтық жұмыспен бір-біріне түсіндіру, жұптық талқылау, миды қозғайтын сұрақтар қойып өздері түсінулерін қамтамасыз ету, ойындар ұйымдастыру және әр түрлі шығармашылық тапсырмалар беру арқылы түрлендіруге болады.

Сабақ барысында бір тапсырмадан басқаша түрлі екінші тапсырмаға ауысып отыру арқылы балалар зейіндерін үйренуде ұзағырақ ұстап тұра алатын болады. Бір мақсатқа негізделген әр түрлі сарындағы тапсырмаларды орындау білім алушыларды жалықтырмай, сабаққа деген ынтасының жоғарылауына алып келеді.

Ұстаздар арасында кеңінен танымал болған «JIGSAW» деген бір әдіс бар. Жаңа тақырыпты түсіндіру кезінде қолданылады.

1. Білім алушыларға фрагменттерге бөлінген тапсырмалармен жұмыс жасау үшін 4-6 адамнан тұратын топтарға ұйымдастырылады. Шағын топтың әрбір мүшесі өз бөлігі бойынша материал табады.

2. Содан кейін бір сұрақты зерттеп жатқан, бірақ әртүрлі шағын топтардан келген оқушылар осы мәселе бойынша сарапшылар ретінде бір топқа жиналады. Бұл "сарапшылардың кездесуі" деп аталады.

3. Әрі қарай олар өздерінің шағын топтарына оралып, басқа топ мүшелеріне өздері үйренген барлық жаңа нәрселерді үйретеді. Олар өз кезегінде тапсырманың бір бөлігі туралы есеп береді.

Барлық фрагменттердің мәліметтерін игерудің жалғыз жолы-командалық серіктестерді мұқият тыңдау және маңызды жерлерін түртіп алу болғандықтан, мұғалімнің қосымша күш-жігері қажет емес. Студенттер жолдастарының өз тапсырмаларын адал орындауына мүдделі, өйткені бұл олардың қорытынды бағасынан көрінеді. Осылайша бүкіл жаңа тақырыпты 100% сынып жұмыс жасау арқылы бір-біріне түсіндіріп шығады.[4]

Интерактивті тапсырмаларды ұйымдастырудың өзіндік шарттары бар:

1. Қатысушылар жұмысқа белгілі бір дәрежеде барлығы қатысуы керек
2. Осы мақсатта барлық қатысушыларды талқылау процесіне қосуға мүмкіндік беретін технологияларды қолдану керек.
3. Оқушылардың психологиялық дайындығының болуы керек. Сабаққа келген барлық оқушы үздіксіз оқу процесіне дайын болып тұруы керек.
4. Интерактив технологиясында білім алушылардың саны көп болмауы тиіс. Қатысушылар саны мен оқу сапасы бір біріне тікелей тәуелді болуы мүмкін. Қатысушылардың оңтайлы саны-25 адамға дейін.
5. Сабақты өткізетін орын мен столдар орын ауыстыруға, топқа бөлінуге ыңғайлы болғаны жөн.
6. Ережелер мен регламентті нақты бекіту. Бұл туралы ең басында келісіп, оны бұзбауға тырысу керек. Мысалы: барлық қатысушылар кез-келген көзқарасқа төзімділік танытады, құрметтейді.[5]

ҚОРЫТЫНДЫ

Сабақтарды жүргізудің дәстүрлі түрлерімен салыстырғанда, интерактивті оқыту мұғалім мен оқушының өзара әрекеттесуін өзгертеді: мұғалімнің белсенділігі оқушылардың белсенділігіне жол береді, ал мұғалімнің міндеті олардың бастамашылдығы үшін жағдай жасау болады.

Диалогтық оқыту барысында оқушылар сыни тұрғыдан ойлауды, жағдайларды талдау және соған сәйкес күрделі мәселелерді шешуді, балама пікірлерді таразылау, ойластырылған пікірлерді қабылдау, пікірталастарға қатысу және басқа адамдармен сөйлесуді үйренеді. Ол үшін сабақтарда жұптық және топтық жұмыс, ғылыми жобалар, рөлдік ойындар, құжаттармен жұмыс және әр түрлі ақпарат көздері, шығармашылық жұмыстар ұйымдастырылады.

Оқытудың интерактивті әдісін қолдану нәтижесінде мектеп оқушыларында:

- мақсат қою және жету қабілеті артады;
- игерген білімнен ләззат алу қабілеті және әрдайым жаңа білімге, зерттеуге деген ұмтылыс пайда болады;
- парасат пен пайымның кеңеюі, белгілі бір заңдылықтардың пайда болу себептерін түсінуге бейімділік пайда болады;
- үйренуге бейімділік артады;
- қажетсіз ақпараттан арылып, шын мәнінде маңызды фактілерге назар аудару мүмкіндігі артады.[6]

Сабақтарда интерактивті әдісті қолданған кезде оқушылар тез ойлауға, жағдайларды талдауға, тәуелсіз шешімдер жасауға, өз ойларын қысқаша және нақты айтуға үйренеді. Әрбір оқушы бірлескен зерттеуге және мәселені шешуге, рөлдік ойынға немесе белгілі бір жағдайды талдауға, топтық талқылауға немесе миға шабуыл жасауға қатысады. Сондықтан оқытудың интерактивті әдістері белсенділікті, логикалық ойлауды, тәуелсіздікті, жауапкершілікті, басқа адамдарды түсінуді және ынтымақтастықты дамытуға ықпал етеді. Интерактивті әдісті қолдану оқушының өзінің жетістігін, интеллектуалды жетілуін сезінетін, білім беру процесінің өзін нәтижелі ететін қолайлы оқу жағдайларын жасайды. Алайда, әр ұстаздың өз пәні мен тақырыбына сәйкестендіруі немесе жаңаларын ойлап табуы ұзақ уақытты, көп күш пен қажымас қайратты талап етеді. Дегенмен де, балалардың көздеріндегі білімге деген ұмтылыс пен отты көру өте көп еңбектенуге тұрады.

ҚОЛДАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Корнеева, Л.И. Современные интерактивные методы в системе повышения квалификации руководящих кадров в Германии :зарубежный опыт // Университетское управление. – 2004.- № 4. – С.17
2. Коротаяева, Е.В. Обучающие технологии в образовательной деятельности учащихся: учебное пособие для студентов пед. учебных заведений / Е.В. Коротаяева. - М.: Издательский центр «Академия», 2002г.
3. Гузеев, В.В. Эффективные образовательные технологии: учебное пособие для студентов пед. учебных заведений /В.В. Гузеев. - М.: НИИ школьных технологий, 2006г. - 208с.
4. Савельев, А.Я. Традиционные и инновационные технологии // Школьные технологии. -1998г.- №5 - С.25
5. Суворова, Н.И. Интерактивное обучение: новые подходы// Учитель. -2000г.- №1.- С.57
6. Якиманская, И.С. Технология личностно-ориентированное обучение в современной школе: учебное пособие для студентов пед. учебных заведений / И.С. Якиманская. - М.: Сентябрь. -1996г. - 85с.

МЕТОДЫ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ ДЛЯ ОПРЕДЕЛЕНИЯ ТРЕНДОВ

Смадинов Р.

Международный университет Астана, Астана, Казахстан

E-mail: r.smadinov@gmail.com

Аннотация. Данная работа посвящен изучению различных методов интеллектуального анализа данных, которые могут использоваться для определения трендов. Тренды являются важным инструментом для прогнозирования будущих изменений и развития в различных областях. В работе рассмотрены такие методы как регрессионный анализ, кластерный анализ, деревья решений и нейронные сети. Описаны основные принципы работы каждого из данных метода, а также представлены примеры их применения. Помимо этого для каждого метода также описаны их преимущества и недостатки, а также возможные области применения. Выводы работы показывают, что все рассмотренные методы имеют свои преимущества и недостатки в анализе трендов, и выбор метода зависит от характеристик данных и целей исследования. Результаты обзора могут быть полезными для исследователей и практиков, работающих с данными.

Ключевые слова: интеллектуального анализа данных, тренды, регрессионный анализ, кластерный анализ, деревья решений, нейронные сети.

ВВЕДЕНИЕ

В современном мире огромное количество информации генерируется каждую секунду. Это стало возможным благодаря стремительному развитию компьютерных технологий и появлению интернета. Все это вместе привело к тому, что люди получили возможности для обработки и анализа больших объемов данных, что способствовало развитию такого направления как интеллектуального анализа данных. Интеллектуальный анализ данных является совокупностью методов и техник анализа данных, которые позволяют извлекать знания и информацию из больших объемов данных, используя алгоритмы машинного обучения и различные статистические методы.

В целом история интеллектуального анализа данных можно проследить еще 1960-х годах с разработки методов машинного обучения, включающих в себя алгоритмы классификации и кластерного анализа. Однако как термин интеллектуального анализа данных в исследовательском сообществе начал использоваться только 1980-х годах [1]. Начиная с 2000-х годах с появлением больших данных и развитием интернета интеллектуального анализа данных стало

еще более актуальным и широко используемым инструментом. Сейчас интеллектуального анализа данных является неотъемлемой частью многих отраслей и используется для решения различных задач, таких как прогнозирование и определение трендов, маркетинговые исследования, анализ медицинских данных и т.д. Например, в финансовой сфере методы интеллектуального анализа данных позволяют анализировать данные о ценах на акции, валютные курсы, процентные ставки и другие финансовые показатели для прогнозирования будущих изменений на рынке. Это позволяет инвесторам и финансовым аналитикам принимать более осознанные решения, основанные на анализе трендов и прогнозах.

Целью данной работы является ознакомить людей с основными методами интеллектуального анализа данных для определения трендов.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Существует множество методов интеллектуального анализа данных, которые могут быть использованы для различных задач анализа данных, включая определение трендов. Тренды — это долгосрочные изменения в данных, которые могут указывать на направление развития, успешность бизнеса и т.д. Определение трендов может быть важным инструментом для принятия решений, особенно в условиях быстро меняющейся среды. Методы интеллектуального анализа данных могут различаться по подходам и применяемым алгоритмам. Однако в целом их можно поделить на классические методы и новые методы [2]. К классическим можно отнести различные статические методы как регрессионный анализ, а также такие методы как кластеризация. К новым можно отнести дерево решения и нейронные сети. Хотя существует ряд других методов, однако в данной работе будут рассмотрены эти четыре так как они являются самыми распространёнными методами интеллектуального анализа данных.

РЕГРЕССИОННЫЙ АНАЛИЗ

Одним из классических методов является регрессионный анализ. Регрессия — это функция интеллектуального анализа данных, которая предсказывает число [3]. Для проведения регрессионного анализа нужно иметь данные, включающие значения зависимой и независимых переменных. Для нахождения связи между переменными в регрессионном анализе используются математические модели, которые могут быть линейными или нелинейными. Линейная регрессия — это наиболее распространенный метод регрессионного анализа. Линейная регрессия позволяет определить тренд и прогнозировать значения зависимой переменной на основе значений независимой переменной. Пример использования линейной регрессии: предположим, у нас есть данные о продажах автомобилей за последние 5 лет. Мы хотим определить, как будет меняться продажа автомобилей в следующие годы на основе имеющихся данных в таблице 1.

Таблица 1. Продажи автомобилей

Год	Продажи (тысяч штук)
2018	150
2019	165
2020	180
2021	195
2022	210

Для построения модели линейной регрессии вам нужно найти уравнение прямой, которая наилучшим образом подходит для описания зависимости между этими двумя переменными. Это можно сделать с помощью метода наименьших квадратов, который позволяет найти такую прямую, чтобы сумма квадратов отклонений точек от нее была минимальной. В линейной регрессии уравнение прямой имеет вид:

$$y = \beta_0 + \beta_1 x$$

где y - зависимая переменная, x - независимая переменная, β_0 - коэффициент сдвига, β_1 - коэффициент наклона.

Коэффициенты β_0 и β_1 находятся путем минимизации суммы квадратов отклонений точек от прямой. В нашем случае коэффициент сдвига составил - 29 835, а коэффициент наклона 15. Это означает что мы прогнозируем рост продаж на 15 тысяч штук ежегодно.

Однако вместе с тем у регрессионного анализа есть ряд недостатков:

Ограниченность моделью: Регрессионный анализ основан на определенной модели, которая может не соответствовать действительности в некоторых случаях. Модель может не учитывать все факторы, влияющие на результаты, или не учитывать некоторые неточности в данных.

Чувствительность к выбросам: Регрессионный анализ очень чувствителен к выбросам. Даже один выброс может сильно повлиять на результаты модели.

Сложность интерпретации: Интерпретация результатов регрессионного анализа может быть сложной, особенно если модель содержит множество переменных и сложные взаимодействия между ними.

Мультиколлинеарность: Если в модели присутствует мультиколлинеарность (когда несколько независимых переменных сильно коррелируют друг с другом), результаты могут быть неточными или недостоверными.

КЛАСТЕРНЫЙ АНАЛИЗ

Кластерный анализ — это группа статистических методов, которые широко используются для интеллектуального анализа данных [4]. Суть данного метода заключается в выявлении групп (кластеров) объектов, сходных друг с другом, и различающихся с объектами других групп. Цель кластерного анализа заключается в том, чтобы найти внутренние структуры данных и обнаружить скрытые закономерности, которые могут быть полезны для дальнейшего анализа. Также кластерный анализ может помочь в определении трендов путем группировки данных в кластеры. Тренды могут быть обнаружены в кластерах, которые имеют схожие характеристики и поведение. Например, если мы анализируем данные о продажах в разных регионах, кластерный анализ может помочь нам определить группы регионов с похожими показателями продаж, которые могут указывать на определенный тренд в продажах.

Далее мы разберем как происходит кластерный анализа. Предположим, у нас есть таблица 2, в которой записаны данные о покупках клиентов в магазине. Мы хотим разделить клиентов на кластеры в зависимости от их покупательского поведения.

Таблица 2. Покупки клиентов

Клиент	Количество покупок	Общая сумма покупок, тенге
A	2	400
B	3	800
C	1	200
D	4	1000
E	2	500

Сначала необходимо выбрать параметры, которые мы будем использовать для кластеризации. В данном случае мы будем использовать два параметра:

количество покупок и общую сумму покупок. После чего необходимо выбрать метод кластеризации. В данном случае мы будем использовать один из наиболее популярных и простых алгоритмов кластеризации, а именно метод k-средних. Следующим шагом будет выбор количества кластеров, на которые мы хотели бы разделить наши данные. Для этого также существует множество методов, однако в данном случае мы предположим, что хотим получить 3 кластера. Теперь мы можем приступить к кластеризации данных. Результаты разделения данных на кластеры можно наблюдать на рисунке

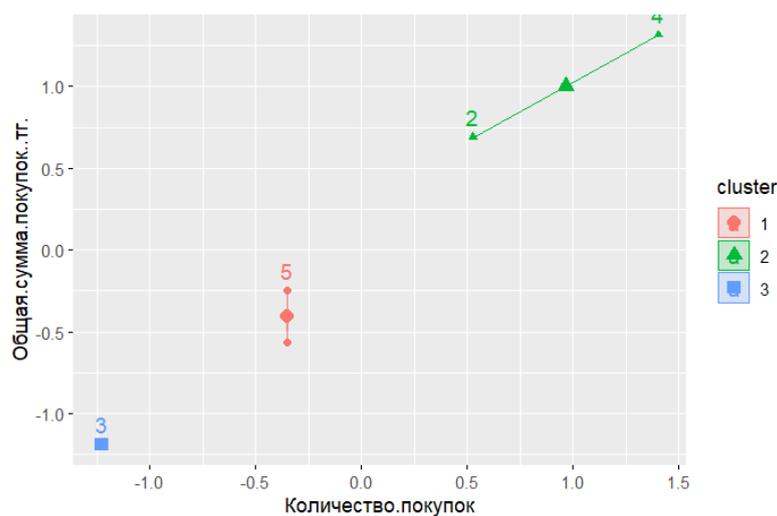


Рисунок 1. Результат кластеризации

В конце концов наши полученные данные можем добавить в таблицу 2. В результате чего наша таблица 3 будет отображать новую колонку делящую наши данные по кластерам. Эти результаты в дальнейшем мы можем использовать в комбинации с другими методами.

Таблица 3. Результат кластеризации

Клиент	Количество покупок	Общая сумма покупок, тенге	Кластер
A	2	400	1
B	3	800	2
C	1	200	3
D	4	1000	2
E	2	500	1

Вместе с тем данный метод имеет ряд своих недостатков:

Выбор числа кластеров: одним из основных недостатков кластерного анализа является необходимость выбора числа кластеров заранее. Это может быть проблематичным, особенно если данные не имеют явно выраженных кластеров или если кластеры пересекаются.

Выбор алгоритма кластеризации: в кластерном анализе необходимо определить расстояние между объектами и кластерами. Выбор определенного алгоритма может сильно влиять на результаты кластеризации.

Чувствительность к выбросам: кластерный анализ может быть чувствителен к выбросам в данных, что может привести к неправильному разбиению на кластеры.

ДЕРЕВО РЕШЕНИЯ

Дерево решений является основной технологией, используемой для классификации и прогнозирования. Обучение модели дерева решений — это типичный индуктивный алгоритм, основанный на экземпляре, который фокусируется на правилах классификации, отображаемых в виде деревьев решений, выведенных из группы беспорядка и нерегулярного экземпляра [5].

При использовании деревьев решений модель прогнозирует целевую переменную, используя рекурсивное разбиение на наборы данных, основанных на значении различных предикторов. В целом, деревья решений могут быть полезными инструментами для идентификации и анализа трендов в данных. Они позволяют выявлять закономерности и зависимости между различными факторами и временными периодами, что может помочь в прогнозировании будущих трендов и принятии бизнес-решений

Предположим, что у нас есть набор данных о продажах различных продуктов в магазине. Мы хотим определить, какие факторы наиболее сильно влияют на продажи и какие продукты находятся в наибольшем спросе. С помощью деревьев решений мы можем построить модель, которая будет учитывать различные факторы, такие как цена продукта, наличие скидок, тип продукта и т.д., и определить, какие продукты наиболее востребованы в зависимости от этих факторов. Например, дерево решений может показать, что наибольший спрос на продукты низкой ценовой категории, если они также имеют скидку, и что продукты высокой ценовой категории находятся в большом спросе только при отсутствии альтернативных продуктов. Таким образом, с помощью деревьев решений мы можем легко определить, какие факторы наиболее сильно влияют на продажи, и какие продукты являются наиболее востребованными в зависимости от этих факторов. Это позволяет нам принимать более обоснованные решения в области маркетинга и продаж.

Деревья решений также имеют несколько недостатков:

Склонность к переобучению: Деревья решений могут быстро переобучаться, что означает, что они могут слишком точно подстроиться под обучающие данные и не смогут обобщать новые данные.

Чувствительность к выбросам: Деревья решений могут быть чувствительны к выбросам, что означает, что даже небольшие изменения в данных могут привести к существенным изменениям в результатах.

Неспособность обрабатывать пропущенные данные: Деревья решений не могут обрабатывать пропущенные данные, что может привести к искажению результатов.

Неспособность учитывать зависимости между переменными: Деревья решений могут быть недостаточно гибкими, чтобы учитывать сложные зависимости между переменными в данных.

НЕЙРОННЫЕ СЕТИ

Искусственная нейронная сеть, обычно называемая нейронной сетью, представляет собой математическую модель или вычислительную модель, вдохновленную структурой или функциональными аспектами биологических нейронных сетей [6]. Суть ее заключается в использовании алгоритмов машинного обучения, который пытаются обнаружить закономерности для построения прогнозных моделей на основе больших исторических баз данных [1]. Нейронные сети состоят из большого количества связанных между собой узлов (нейронов), которые обрабатывают информацию. Каждый нейрон принимает входные данные, обрабатывает их, а затем передает результаты следующему нейрону. В результате чего нейронные сети могут определять тренды и выявлять скрытые паттерны, которые могут быть неочевидными при анализе данных вручную. Одним из примеров использования нейронных сетей может быть анализ цен акции и выявления трендов на рынке.

Предположим, что мы располагаем историческими данными о ценах на акции компании за последние несколько лет. Мы можем с помощью нейронных сетей создать модель, которая будет находить связь между различными факторами (например, экономическими показателями, новостными событиями, политической обстановкой и т.д.) и изменением цены на акции. На основе этого анализа нейронные сети могут предсказать будущие тренды на рынке, что может быть полезно для инвесторов и трейдеров.

Несмотря на многие преимущества, нейронные сети также имеют свои недостатки. Некоторые из них:

Нейронные сети могут быть сложными в понимании: Это может быть сложным заданием для не специалистов, так как они могут содержать множество слоев, нейронов и параметров, что усложняет их интерпретацию.

Нейронные сети могут склонны к переобучению: Если сеть будет обучена на слишком маленьком или неудовлетворительном наборе данных, это может привести к переобучению, когда модель будет хорошо работать на обучающих данных, но плохо работать на новых данных.

Требуется большое количество данных: Некоторые типы нейронных сетей, такие как глубокие нейронные сети, могут потребовать очень большого количества данных для достижения высокой точности.

Обучение может занять много времени: Для обучения больших нейронных сетей может потребоваться значительное количество времени и вычислительных ресурсов.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В данной работе мы рассмотрели четыре основных метода интеллектуального анализа данных для определения трендов: регрессионный анализ, кластерный анализ, деревья решений и нейронные сети. Каждый метод имеет свои преимущества и ограничения, и выбор метода зависит от конкретной задачи и доступных данных.

Регрессионный анализ позволяет определить, как одна или несколько независимых переменных влияют на зависимую переменную. Благодаря чему данный метод позволяет прогнозировать значения зависимой переменной на основе значений независимых переменных. Недостатком регрессионного анализа является чувствительность к выбросам, сложность интерпретации.

Кластерный анализ позволяет выделить группы объектов с похожими характеристиками и выявить закономерности в данных. Он может быть полезен при определении кластеров покупателей, сегментации рынка, классификации клиентов и т.д. Недостатком кластерного анализа может быть необходимость предварительной обработки данных, выбор количества кластеров и интерпретация результатов.

Деревья решений — это метод машинного обучения, который строит дерево, представляющее последовательность правил для классификации объектов. Деревья решений могут быть полезны при выявлении важных переменных, предсказании результатов и определении важных факторов в процессе принятия решений. Недостатком данного метода является склонность к переобучению, необходимость выбора правильного критерия и интерпретация результатов.

Нейронные сети — это сложные математические модели, которые используются для предсказания и классификации. Они полезны, когда данные большого объема либо когда данные нелинейно зависимы, а также когда в данных наблюдаются выбросы. Недостатком нейронных сетей может быть сложность их построения, необходимость большого объема данных и сложности при интерпретации результатов.

ВЫВОДЫ

Интеллектуальный анализ данных является мощным инструментом для определения трендов в данных. В целом, выбор метода интеллектуального анализа данных для определения трендов зависит от специфики задачи и доступных данных. Однако, использование комбинации методов может дать наилучший результат, улучшив точность и интерпретируемость результатов. В целом данная работа может быть полезна для будущих специалистов в качестве ознакомительного материала чтобы кратко ознакомиться что такое интеллектуального анализа данных какие есть основные методы в данном направлении, какие недостатки у данных методов.

СПИСОК ЛИТЕРАТУРЫ

1. Coenen, F. Data mining: Past, Present and Future. *The Knowledge Engineering Review*, vol. 26, no. 1, pp. 25–29, 2011. doi: 10.1017/S0269888910000378
2. Berson A, Simith S, Thearling K. *Building data mining applications for CRM*. McGraw-Hill, 2000.
3. Singh N., Raw R. S., Chauhan R. K. Data Mining With Regression Technique. *Journal of Information Systems and Communication*, vol. 3, no. 1, pp. 199–202, 2012. ISSN: 0976-8742 & E-ISSN: 0976-8750
4. Antonenko, P. D., Toy, S., & Niederhauser, D. S. Using cluster analysis for data mining in educational technology research. *Educational Technology Research and Development*, vol. 60, no. 3, pp 383–98, 2012. doi:10.1007/s11423-012-9235-8
5. Qing Dai, Chun-ping Zhang and Hao Wu. Research of Decision Tree Classification Algorithm in Data Mining. *International Journal of Database Theory and Application*, vol. 9, no. 5, pp. 1-8, 2016. doi: 10.14257/ijdta.2016.9.5.01
6. Amarendra, K., Lakshmi, K.V., Ramani, K.V. Research on Data Mining Using Neural Networks. *International Journal of Computer Science and Informatics*, vol. 2, no. 3, pp. 160-168, 2013. doi: 10.47893/IJCSI.2013.1085

ОБЗОР МЕТОДОВ И ТЕХНОЛОГИИ РАЗРАБОТКИ ЭЛЕКТРОННЫХ ОБРАЗОВАТЕЛЬНЫХ РЕСУРСОВ ДЛЯ ОНЛАЙН ОБУЧЕНИЯ

А.Н. Құмарова, Б. Ж.Ергеш

Международный университет Астана, Астана, Казахстан

E-mail: kumarova.alinaa@mail.ru

Аннотация. В настоящее время изучение методов и технологии разработки электронных образовательных ресурсов для онлайн обучения является актуальной задачей. В данной статье проанализированы методы создания образовательных электронных ресурсов в учебном процессе в высшем учебном заведении и их применение. Цель данного исследования состоит в изучении литературы по теме методы и технологии разработки электронных образовательных ресурсов для онлайн обучения. На сегодняшний день важным и необходимым фактором является образованность граждан. Она играет главную роль в процессе информатизации общества и выполняет основную задачу: обеспечить развитие информационно-коммуникационных технологий в государстве и обществе в целом. Из этого следует, что учебные заведения несут ответственность за выполнение данной задачи. Они должны способствовать в процессе обучения развитию умственного мышления, которого можно добиться, используя передовые педагогические технологии. При реализации образовательных программ используются различные образовательные технологии, в том числе дистанционные образовательные технологии, электронное обучение.

Ключевые слова: электронные образовательные ресурсы, методы онлайн обучения, технологии онлайн обучения, онлайн обучение, e-learning.

ВВЕДЕНИЕ

В последнее время технологии онлайн обучения становятся одним из приоритетных направлений в развитии современного образования в Казахстане и по всему миру.

Во время пандемии активно использовались технологии онлайн обучения во всех сферах нашей деятельности, охватывая также образование. Для расширения и развития онлайн обучения важнейшей задачей является методы и технологии разработки электронных образовательных ресурсов для онлайн обучения. В век развития технологии и компьютеров важно создание и внедрение методов и технологии разработки электронных образовательных ресурсов для онлайн обучения.

В настоящее время электронные образовательные ресурсы включают в себя не только тексты по определенным темам, но и являются интерактивными и мультимедийными.

С каждым днем появляются все больше онлайн ресурсов, приложения и веб-сайты, которых учителя и преподаватели могут использовать в разработке плана урока, практических занятий и лекционных занятиях. Все больше денег вкладывается в технологию, поставляемую в школы, а учащиеся стали более грамотными в области технологий, чем когда-либо.

Возможности методов и технологии разработки электронных образовательных ресурсов для онлайн обучения

Традиционные методы обучения не могут быть заменены онлайн-обучением. Обучение в классе имеет свои ценные преимущества, такие как навыки межличностного общения, которым оно обучает, и возможность совместного обучения. Однако, когда они объединены, это может предоставить новые возможности для обучения в классе и за его пределами, облегчая жизнь как учеников, так и учителей:

1. Это делает обучение доступным большему количеству людей

Традиционно инвестиции в дополнительные образовательные ресурсы для учащихся за пределами школы, такие как учебники и частные репетиторы, были очень дорогими. Это действительно ограничивало тех, кто имел доступ к дополнительным ресурсам, необходимым им для успеха в учебе. Сегодня образовательные онлайн-ресурсы легко доступны любому, у кого есть подключение к Интернету, независимо от того, используют ли они ноутбук, iPad или смартфон, и многие из этих ресурсов доступны бесплатно. Это делает более качественное образование более доступным для большего количества студентов, независимо от их финансового положения.

Образовательные технологии делают обучение доступным не только с финансовой точки зрения, но и облегчают преодоление некоторых барьеров, с которыми приходится сталкиваться при обучении с ограниченными возможностями. Например, электронные учебники могут облегчить доступ к ресурсам для тех, кому трудно ходить в библиотеку из-за физических недостатков. Цифровые учебники часто имеют больше возможностей для представления информации, и часто формат цифрового учебника легче изменить, чтобы сделать информацию доступной для слабовидящих учащихся.

2. Предоставляет широкий спектр ресурсов для всех стилей обучения

Исследования показали, что стиль обучения так же важен, как и способности, когда речь идет об академической успеваемости. В условиях классной комнаты

учителю почти невозможно адаптировать каждый аспект учебной программы к уникальному стилю обучения каждого из своих учеников. К сожалению, это означает, что некоторым учащимся с особым стилем обучения определенные части учебной программы будет труднее запомнить или понять.

Однако через Интернет у нас теперь есть доступ к сотням различных типов образовательных ресурсов, от веб-сайтов до обучающих игр, подкастов и аудиокниг. Это чрезвычайно полезно для учащихся, которые используют определенный стиль обучения для закрепления информации в памяти. Их могут либо использовать учителя, чтобы сделать уроки привлекательными для всех типов учащихся, либо учащиеся могут искать их дома для дополнительной помощи в учебе.

3. Обеспечивает мгновенную обратную связь о работе

Получение отзывов о работе является важной частью обучения и воспитания. Это помогает как учителям, так и учащимся понять прогресс и способности учащегося, а также то, насколько хорошо они поняли аспекты учебной программы. Однако после завершения оценки обычно проходят недели, прежде чем учащийся получит отзыв о своей работе, после чего он может не вспомнить вопросы, на которые ответил в тесте, и, следовательно, с меньшей вероятностью будет действовать в соответствии с полученной обратной связью.

Большинство онлайн-тестов и обучающих игр обеспечивают мгновенную обратную связь с пользователем, когда сразу после отправки ему сообщают, правильный или неправильный ответ. Было доказано, что это лучше помогает учащимся обеспечить значимую связь с их работой, и это стиль обратной связи, который также помогает учащимся развивать личные цели в отношении их работы.

4. Имитирует индивидуальный стиль обучения

В классе учащимся, которые изо всех сил пытаются понять содержание урока, легче остаться незамеченными. И если ученику действительно требуется дополнительное внимание со стороны учителя, этого нельзя добиться, не откладывая урок для других детей и не откладывая их учебное время. Многие образовательные онлайн-инструменты имеют возможности искусственного интеллекта, которые позволяют образовательной программе, уроку или игре оценивать сильные и слабые стороны учащегося за считанные секунды и создавать вопросы и образовательный контент, специально нацеленные на самые слабые области знаний учащегося. Это то, чего просто невозможно достичь в классе в той же степени, особенно в Великобритании, где в среднем одни из самых больших размеров классов, чем в большинстве школ в развитых странах.

5. Экономит время и деньги школы

Сегодня в преподавании задействовано огромное количество бюрократии, от планирования уроков и выставления оценок до подготовки к школьным бдениям. К сожалению, хотя некоторые из них необходимы для работы школы [1].

МЕТОДЫ ЭЛЕКТРОННОГО ОБУЧЕНИЯ, КОТОРЫХ МОЖНО ВКЛЮЧАТЬ В ПРОГРАММУ ОБУЧЕНИЯ

Электронное обучение — это любой учебный материал, доставляемый через Интернет. Электронное обучение нашло свое место в мире корпоративного обучения как форма ценного общения и реального взаимодействия. Он имеет много преимуществ как для работодателя, так и для сотрудников — он не только очень эффективен, но и дешевле в исполнении. Custom eLearning Development обеспечивает удобство, гибкость, надежность и масштабируемость любой корпоративной программы обучения. Тем не менее, выбрать среди множества доступных вариантов довольно сложно. Вот некоторые из методов электронного обучения, которые компания может включить в свою корпоративную программу обучения:

1. Интернет-обучение

Интернет-обучение основано на содержании веб-сайта. Сотрудники могут получить доступ к этому веб-сайту со своего личного устройства или через Интернет компании. Веб-сайты предоставляют сотрудникам возможность учиться, когда они могут или хотят. Он не ограничивает обучение конкретным пространством и позволяет пользователям получать доступ к информации в любое время. Веб-сайт также дает возможность добавлять мультимедиа, такие как текст, видео, изображения и многое другое. Это добавляет новое измерение в электронное обучение и делает его более интерактивным и привлекательным для сотрудников. Он также знакомит сотрудников с веб-инструментами, чтобы они могли ознакомиться со способами внутреннего общения в вашей компании.

2. Виртуальные классы

Виртуальные классы — это, по сути, современная версия корпоративного обучения под руководством инструктора. Это позволяет как инструкторам, так и слушателям участвовать в процессе. Преподаватели присутствуют в классе с помощью программного обеспечения для видео, в то время как посетители присутствуют физически. Это также можно сделать удаленно с помощью программного обеспечения для конференц-связи. Эта модель электронного обучения поощряет сотрудничество, идеи и взаимодействие, помогая создать среду для личных связей. «Присутствие» эксперта позволяет задавать вопросы, получать живой опыт обучения и человеческий фактор, которого нет в других режимах.

3. Видеомодули

Видеомодули производятся на основе обучающих видеороликов, которые были сделаны заранее для ознакомления сотрудников. Эти модули могут быть анимированными или с инструктором-человеком. Возможности безграничны, когда дело доходит до создания видеороликов для корпоративной программы обучения. Это также очень гибкий режим электронного обучения, поскольку пользователи могут получить доступ к видео в любое время. У них также есть возможность воспроизводить видео столько раз, сколько они пожелают. Когда дело доходит до понимания концепции, видео часто работает намного лучше, чем текст, потому что людям нравится подача на основе графики. Цвета, четкое объяснение и формат видео упрощают электронное обучение для сотрудников.

4. Специализированное электронное обучение

Каждая организация имеет разные потребности в корпоративном обучении, и каждый сотрудник или группа сотрудников имеют разные потребности в корпоративном обучении. В таких сценариях серийные и общекорпоративные учебные модули просто не подходят. Благодаря индивидуальной разработке электронного обучения существует гибкость, позволяющая выбирать и настраивать корпоративные программы обучения. С помощью электронного обучения работодатели могут установить личную связь со своими сотрудниками, поскольку они могут точно удовлетворить свои потребности и не заставлять их изучать то, что они, возможно, уже знают или им не нужно учиться.

5. Обучение работе с социальными сетями

Мир стал социальным, и работодатели просто догоняют его, особенно когда речь идет о корпоративном обучении. Эта модель электронного обучения создает среду для совместной работы сотрудников и использует возможности социальных сетей. Через такие платформы, как Facebook, Instagram и Twitter, эта программа предоставляет необходимые знания и делает это слаженно, что способствует командной работе и сотрудничеству. Если социальные сети являются ключевой частью вашего сотрудничества

6. Микрообучение

Микрообучение относится к доставке контента электронного обучения в виде информационных самородков. Каждый модуль длится, как правило, не более 10 минут и всесторонне решает одну цель обучения за раз. При микрообучении каждый модуль посвящен только одной теме, что позволяет пользователям и читателям более эффективно запоминать информацию. Благодаря микрообучению корпоративное обучение выходит на новый уровень эффективности, поскольку оно позволяет улучшить показатели удержания и находит способ бороться с кривой забывчивости. После принятия этого метода

электронного обучения стратегия корпоративного обучения погружается в установление прочной личной связи со своими сотрудниками. Средняя продолжительность концентрации внимания людей составляет не более 8 минут, и микрообучение борется с этим, создавая короткие, актуальные и лаконичные фрагменты модулей электронного обучения, которые делают корпоративное обучение более успешным.

7. Мобильное обучение

Когда дело доходит до электронного обучения, доступность играет решающую роль. Что может быть лучше, чтобы оставаться доступным, чем идти по мобильному маршруту. Благодаря мобильному электронному обучению сотрудники имеют доступ к необходимой информации, не выходя из дома или даже во время поездки на поезде на работу. Мобильное обучение превращает корпоративное обучение прямо в руки сотрудников, позволяя им свободно обращаться к нему по своему усмотрению [2].

ЭЛЕКТРОННЫЙ ОБРАЗОВАТЕЛЬНЫЙ РЕСУРС

Наиболее разработанным направлением информатизации образования является применение электронного образовательного ресурса (ЭОР) непосредственно в учебном процессе. Понятие ЭОР является устоявшимся понятием. В отличие от образовательных ресурсов в целом, ЭОР можно определить как средство, к которому обращаются с целью получения образования, как ресурс, содержащий информацию образовательного характера. Понятие ЭОР включает в себя учебную, методическую, справочную, организационную и другую информацию, необходимую для эффективной организации образовательного процесса, представленную в цифровом виде. В настоящее время существует множество определений понятия электронные (цифровые) образовательные ресурсы, но в большинстве из них не затронуто такое важное понятие, как методические рекомендации. На наш взгляд, это важная составляющая любого образовательного ресурса, ведь с помощью методических рекомендаций преподавателю проще ориентироваться в многообразии электронных образовательных ресурсов. Учебный материал должен быть структурирован в ней таким образом, чтобы сформировать у обучаемого личный тезаурус научно предметных знаний, развить навыки владения профессиональными приемами, методами и способами их применения. Одной из новых возможностей для обучения является «самообразование». Термин «самообразование» означает такую организацию учебного процесса, при которой преподаватель разрабатывает учебную программу, главным образом базирующуюся на самостоятельном обучении. Самообразование позволяет учиться жителям регионов, где нет иных возможностей для профессиональной подготовки или получения качественного высшего образования, нет университета нужного профиля или преподавателей требуемого уровня квалификации. В последнее время наиболее близким по

значению и сути данного определения является так называемое «дистанционное образование». Главной проблемой развития самообразования является создание новых методов и технологий обучения, отвечающих телекоммуникационной среде общения. В этой среде ярко проявляется то обстоятельство, что обучаемые – это не просто пассивные потребители информации, а в процессе обучения они создают собственное понимание предметного содержания обучения. Важно, чтобы обучаемый научился самостоятельно приобретать знания, пользуясь разнообразными источниками информации; умел с этой информацией работать, используя различные способы познавательной деятельности и имел при этом возможность работать в удобное для него время [3].

В своей работе [4] авторы рассматривают методологические проблемы создания и использования электронной информации в учебном процессе, даются рекомендации по разработке различных видов электронных учебных изданий. Работа написана для педагогов, специалистов в области информационных технологий и студентов педагогических учебных заведений

В книге [5] излагается методология разработки компьютерных учебников и обучающих систем. Основное внимание авторы уделяют стадии концептуального проектирования, на которой формируется облик продукта, определяется его содержательная направленность, специфицируются основные функции и важнейшие характеристики, вырабатываются принципиально дидактические и программно-технические решения. Книга написана для действующих и потенциальных создателей компьютерных средств обучения (ученых, преподавателей, методистов, специалистов по информационным технологиям), организаторов учебного процесса, студентов старших курсов и аспирантов.

В содержание издания [6] включены разделы, посвященные сущности и специфике использования электронных средств обучения в подготовке школьников, общим подходам к созданию наглядных электронных средств обучения, особенностям разработки образовательных мультимедиа и гипермедиа-ресурсов и использованию для этого специализированных инструментов.

В монографии [7] автор особое внимание уделяет различным аспектам создания и использования образовательных ресурсов. В ней содержится обзор подходов к разработке электронных образовательных ресурсов по компьютерным наукам. В качестве примеров реализации описанных методов и инструментов используются разработанные автором программные комплексы: универсальный электронный задачник Programming Taskbook, его специализированные расширения, а также комплекс для преподавателя Teacher Pack.

В связи с пандемии все организации работали в дистанционном режиме, в том числе и организации среднего образования и высшие учебные заведения. Для осуществления учебного процесса с применением дистанционного обучения

общество должен организовать учебные занятия посредством асинхронного и/или синхронного формата обучения и путем самостоятельного освоения учебных материалов для лиц, имеющих временные ограничения возможностей здоровья и не имеющих возможности регулярно посещать университет. Определяет соотношение объема занятий с применением дистанционного обучения. Создает условия профессорско-преподавательскому составу для разработки и/или обновления образовательных ресурсов, онлайн курсов, MOOK.

В свою очередь преподаватель для осуществления учебного процесса с применением дистанционного обучения готовит и предоставляет все необходимые учебные материалы и схемы обучения. Проводит текущий и итоговый контроль результатов дистанционного обучения с использованием форм проверки и контроля знаний, предусмотренные образовательными программами и внутренними нормативными документами [8].

На настоящее время разработки и расширения массовых открытых онлайн-курсов (MOOC) получила новую волну развития в связи с пандемией коронавируса. Важность и необходимость MOOC будут возрастать, однако интеллектуальные системы качественно изменились с момента разработки первых MOOC. Модель интеллектуального MOOC предлагает заложить свою интеллектуальность в его проектирование, используя базу знаний, онтологическую модель дисциплины и соответствующую им систему вопросов и ответов, и интеллектуальный поиск. Отдельной важной частью каждого такого MOOC является интеллектуальная оценка знаний и достижение заявленных результатов обучения. Предлагаемая модель MOOC делает ее более эффективным средством дистанционного, смешанного и любого электронного обучения. Интеллектуальный MOOC обладает возможностью его использования в системах электронного обучения без участия преподавателя [9].

Порядок и вообще подход по организации занятий в дистанционном формате значительно отличается от традиционного подхода. Основной особенностью, естественно, является отсутствие непосредственного контакта с обучающимися и по различным исследованиям уже после 20 минут лекции в традиционном формате обучающийся теряет фокус внимания с лекции. Во время онлайн-лекции (синхронное обучение) обучающийся находится перед экраном или монитором и по некоторым оценкам уже через 7 минут вещания обучающийся начинает отвлекаться, а после 11 минут удержать внимание обучающегося все сложнее. Поэтому простой перенос традиционного занятия в онлайн формат мало эффективен.

Во время проведения практических/семинарских, лабораторных заданий можно давать индивидуальные и групповые задания, которые направлены на закрепление и контроль знаний, умений. Для проведения практических/семинарских занятий рекомендуется использовать методы

проектного, группового обучения, case-study, игровых методов. При проведении лабораторных занятий рекомендуется использовать методы проектного, группового обучения, использовать закупленные университетом виртуальные лаборатории [10].

ВЫВОДЫ

Таким образом, в настоящее время в системе образования важное значение играет применение современных информационных технологий, внедрение современных электронных образовательных ресурсов. Содержание электронных средств учебного назначения должно соответствовать ГОСТ и современным технологиям обучения. В настоящее время разрабатываются различные образовательные электронные Интернет-ресурсы, в том числе с применением самых современных мультимедийно-интерактивных. Также немаловажное значение сыграло появление компьютеров и выход в Интернет практически у каждого жителя нашей страны, что значительно облегчило доступ к электронным ресурсам, получению образования и повышения квалификации с дистанционным формате.

СПИСОК ЛИТЕРАТУРЫ

1. Лапенко М.В. Научно-педагогические основания создания и использования электронных образовательных ресурсов информационной среды дистанционного обучения (на примере подготовки учителей). - Москва, 2014. - 43с.
2. Данилова О.В. Подготовка студентов педагогического вуза к разработке электронных образовательных ресурсов – Чебоксары, 2010. – 24с.
3. Электронные образовательные ресурсы/ Ратнер Ф.Л. // - Казань: КГУ, 2008. – 104с.
4. Теоретические основы создания образовательных электронных изданий. /Беляев М. И., Вымятин В.М., Григорьев С.Г. // - Томск: издательство Томский университет, 2002. – 86с.
5. Разработка компьютерных учебников и обучающих систем / Башмаков А.И., Башмаков И.А. // - Москва: Информационно издательский дом «Филинь», 2003. – 616с.
6. Технология создания электронных средств обучения / Беляев М.И., Гриншкун В.В., Краснова Г.А. // - Разработка Института дистанционного образования Российского университета дружбы народов, 2006. – 130с.
7. Абрамян М.Э. / Инструменты и методы разработки электронных образовательных ресурсов по компьютерным наукам / Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2018. – 206с.
8. Правила организации учебного процесса по дистанционному обучению и в форме онлайн-обучения по образовательным программам высшего и (или) послевузовского образования // Информационно-правовая система нормативных правовых актов Республики Казахстан Эділет (<https://adilet.zan.kz/rus/docs/V1500010768>) Просмотрено 20.11.2022.
9. Бекманова Г., Омарбекова А., Кадеркеева З., Шарипбай А. / Модель разработки интеллектуального массового открытого онлайн-курса // Международная конференция по вычислительной науке и ее приложениям – ICCSA 2020. - 271-281с.

-
10. Бекманова Г. Т., Омарбекова А. С., Ергеш Б. Ж., Айтенова Э. Е., Сериккажина М. С. /Методические рекомендации по проведению занятий в дистанционном и смешанном форматах обучения. // Астана, 2020. – 84с.

ОНЛАЙН ОҚЫТУҒА АРНАЛҒАН ЭЛЕКТРОНДЫҚ БІЛІМ БЕРУ РЕСУРСТАРЫН ӘЗІРЛЕУ ӘДІСТЕРІ МЕН ТЕХНОЛОГИЯЛАРЫНА ШОЛУ

Аннотация. Онлайн оқыту үшін электрондық білім беру ресурстарын әзірлеу әдістері мен технологиялары қазіргі уақытта өзекті сала болып табылады. Бұл мақалада жоғары оқу орнында оқу процесінде білім беру электрондық ресурстарын құрудың мүмкін әдістері талданады. Бұл зерттеудің мақсаты онлайн оқыту үшін электрондық білім беру ресурстарын әзірлеу әдістері мен технологиялары тақырыбындағы әдебиеттерді зерттеу болып табылады. Бүгінгі таңда азаматтардың білімі маңызды және қажетті фактор болып табылады. Ол қоғамды ақпараттандыру процесінде басты рөл атқарады және негізгі міндетті орындайды: мемлекетте және жалпы қоғамда ақпараттық-коммуникациялық технологиялардың дамуын қамтамасыз ету. Бұдан шығатыны, оқу орындары осы тапсырманы орындауға жауапты. Олар оқу процесінде озық педагогикалық технологияларды қолдану арқылы қол жеткізуге болатын психикалық ойлауды дамытуға ықпал етуі керек. Мақалада "білім беру бағдарламаларын іске асыру кезінде әртүрлі білім беру технологиялары, соның ішінде қашықтықтан білім беру технологиялары, электрондық оқыту қолданылады" делінген.

Түйінді сөздер: электрондық білім беру ресурстары, онлайн оқыту әдістері, онлайн оқыту технологиялары, онлайн оқыту, e-learning.

REVIEW OF METHODS AND TECHNOLOGIES FOR DEVELOPING E- LEARNING RESOURCES FOR ONLINE LEARNING

Annotation. Methods and technologies for developing e-learning resources for online learning is a topical area at present. This article analyses the possible methods of creating educational e-resources in the educational process in higher education institution. The aim of this study is to review the literature on the topic of methods and technologies for developing e-learning resources for online learning. Nowadays, the education of citizens is an important and necessary factor. It plays a major role in the process of informatization of society and performs the main task: to ensure the development of information and communication technologies in the state and society as a whole. It follows that educational institutions are responsible for this task. They should facilitate in the learning process the development of intellectual thinking, which can be achieved through the use of advanced pedagogical technologies. The article stipulates that "various educational technologies are used in the implementation of educational programmes, including distance learning technologies, e-learning".

Keywords: e-learning resources, online learning methods, online learning technologies, online learning, e-learning.

RESEARCHING CLOUD TECHNOLOGIES AND ENSURING THEIR SECURITY

Seksenova Zh.M., Kusseпова L.T.

Astana International University, Astana, Republic of Kazakhstan,
seksenova.zhuldyz@bk.ru, lazzatk@mail.ru

Abstract: This paper presents an overview of cloud computing, which is a new computing model that has emerged from various computer technologies such as grid computing, distributed computing, and virtualization. The paper highlights the advantages of cloud computing, including large-scale computation and data storage, virtualization, high expansibility, high reliability, and low-cost services. However, the paper emphasizes that the security problem of cloud computing is a major concern that can hinder its rapid development. Therefore, the paper introduces various cloud computing systems and analyzes the security issues and strategies based on the fundamental concepts and characteristics of cloud computing. In this article, we will give an overview of cloud technologies, computing, highlight their main concepts, architectural principles, modern implementation, as well as research tasks. The purpose of this article is to provide a better understanding of cloud computing design issues and identify important research areas in this important area.

Keywords: cloud technologies, cloud computing, SaaS, PaaS, IaaS, big data

INTRODUCTION

Companies have been storing and protecting data for many decades, but the rise of the internet and the digital age has created new challenges for data storage and security. As a result, cloud computing has become a popular solution for organizations and individuals looking to store and process data securely. Cloud computing allows users to store data on remote servers, which can be accessed over the internet. Overall, cloud computing has revolutionized the way we store and process data, and it is expected to continue to grow in popularity as more businesses and individuals move their data to the cloud.

Cloud technologies refer to a set of tools, services, and infrastructure that are delivered over the internet as a pay-per-use model. These technologies allow users to access and use computing resources, such as servers, storage, databases, applications, and software, without the need for owning and managing the physical hardware and infrastructure. (Shown in Figure 1.)

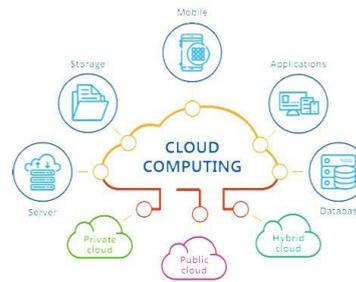


Fig. 1. Cloud Computing [1]

Advantages of cloud computing are availability of processing power, storage, flexibility, scalability, and reducing overhead cost on the IT infrastructure.

There are some disadvantages of cloud computing: dependence on internet connectivity, security and privacy concerns, lack of control over infrastructure, vendor lock-in, compliance and regulatory requirements.

The "NIST Definition of Cloud Computing" section of an article would typically discuss the definition of cloud computing as provided by the National Institute of Standards and Technology (NIST). This definition is widely recognized and used in the industry to describe the characteristics, service models, and deployment models of cloud computing. The article might also discuss the five essential characteristics of cloud computing as defined by NIST: on-demand self-service, broad network access, resource pooling, rapid elasticity, and measured service.

The "Service models" section of an article on cloud computing typically describes the three primary service models for delivering cloud computing services: Infrastructure as a Service (IaaS), Platform as a Service (PaaS), and Software as a Service (SaaS). The section would begin by defining each of these service models. In the section, we will highlight the advantages and disadvantages of each service model. The section might also discuss the different types of applications that are best suited for each service model.

The "Literature survey on cloud computing research" section of an article on cloud computing would typically provide an overview of the existing research in the field, highlighting the most important findings, trends, and gaps in the literature.

The "Overview of state-of-the-art cloud computing literature" section of an article on cloud computing would typically provide an in-depth analysis of the most recent and significant research contributions in the field.

The "Conclusion" section of an article on cloud computing would typically summarize the main points and contributions of the article, and provide some final reflections and recommendations on the topic.

THE NIST DEFINITION OF CLOUD COMPUTING

The National Institute of Standards and Technology (NIST) definition of cloud computing is widely accepted as a standard definition. According to NIST, cloud computing is defined as "a model for enabling ubiquitous, convenient, on-demand network access to a shared pool of configurable computing resources (e.g., networks, servers, storage, applications, and services) that can be rapidly provisioned and released with minimal management effort or service provider interaction"[1]. This cloud model is composed of five essential characteristics, three service models, and four deployment models. (In Figure 2, we can see the benefits cloud computing.)



Fig. 2. Cloud-Computing-Benefits [1]

According to NIST, cloud computing has five essential characteristics: self-service, broad network access, resource pooling, rapid elasticity, and measured service. These characteristics enable cloud computing to provide on-demand access to shared computing resources, including servers, storage, and networking, that can be rapidly scaled up or down as needed. When these characteristics are combined, they create cloud computing infrastructure that contains both a physical layer and an abstraction layer. The physical layer consists of hardware resources that support the cloud services (i.e. servers, storage and network components). The abstraction layer consists of the software deployed across the physical layer, thereby expressing the essential characteristics of the cloud per NIST's definition.

Table 1. Characteristics of cloud computing:

On-demand self-service	Cloud computing users can provision computing resources, such as server time and network storage, as needed, without requiring any interaction with the cloud service provider.
Broad network access	Cloud computing resources are accessible over the network and can be accessed from a wide range of devices, such as laptops, tablets, and smartphones.
Resource pooling	Cloud service providers pool computing resources to serve multiple users and applications. Resources are dynamically assigned and reassigned according to user demand.

Rapid elasticity	Cloud computing resources can be rapidly and automatically scaled up or down to meet changing user demand.
Measured service	Cloud service providers measure and monitor resource usage and provide users with detailed usage reports. Users are only charged for the resources they consume.

SERVICE MODELS

Cloud computing service models provide different levels of abstraction to users, allowing them to choose the level of control they require over their computing resources. According to NIST, there are three service models: SaaS (Software as a Service), PaaS (platform as a Service) and IaaS (Infrastructure as a Service). In fact, most fundamental service models include a combination of IaaS, PaaS and SaaS. These service models may have synergies between each other and be interdependent; for example, PaaS is dependent on IaaS because application platforms require physical infrastructure.

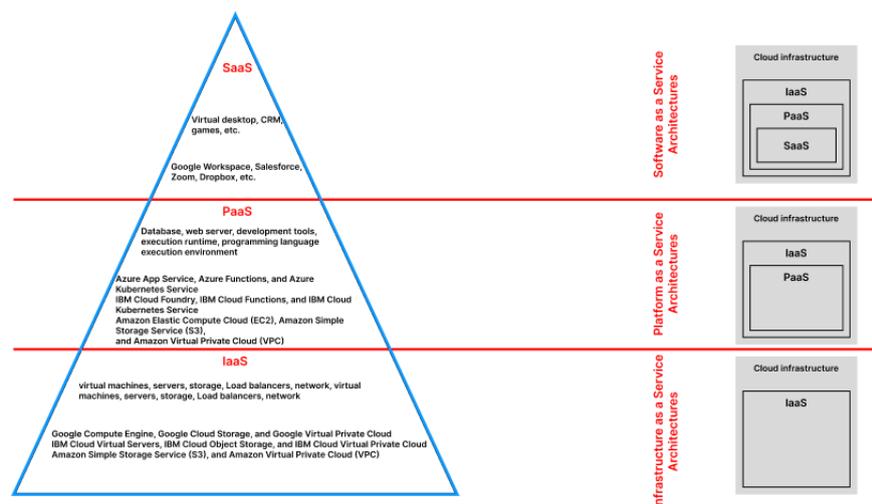


Fig. 3. Service models

For example, Figure 3 shows the service models and the relationship between them. The service models of SaaS, PaaS, and IaaS are often interdependent and can work together to provide a complete solution for businesses.

As you mentioned, PaaS is dependent on IaaS because PaaS platforms require physical infrastructure to run the applications. IaaS provides the underlying physical infrastructure, such as servers, storage, and networking, that PaaS platforms need to function. Without IaaS, PaaS providers would have to invest in their own physical infrastructure, which would be expensive and time-consuming.

Similarly, SaaS applications can be built on top of PaaS platforms, which in turn are built on top of IaaS. SaaS providers can use PaaS platforms to develop and deploy their applications, without having to worry about the underlying infrastructure. This allows SaaS providers to focus on their applications, rather than the infrastructure.

Overall, the synergy between these service models allows businesses to leverage the benefits of cloud computing, such as scalability, flexibility, and cost-effectiveness, while minimizing the need for significant investment in physical infrastructure.

Table 2. Service models

Software as a Service (SaaS)	Platform as a Service (PaaS)	Infrastructure as a Service (IaaS).
SaaS: is a software distribution model in which applications are hosted by a vendor or service provider and made available to customers over a network, typically the Internet.	PaaS: is a category of cloud computing that provides a platform and environment to allow developers to build applications and services over the Internet.	IaaS: is a provision model in which an organization outsources the underlying operating systems, security, networking, storage and servers for developing such applications, services, and for deploying development tools, databases, etc.
Some benefits of SaaS are: Cost savings, Flexible, Stable, Rapid deployment, Accessible, New releases (upgrade)	Some benefits of PaaS are: Teams Can Collaborate From Afar, Flexibility, Cost savings, Maximize uptime, Scale easily	Some benefits of IaaS are: Quick and easy access to enterprise class capabilities, Simplicity, No investment in hardware, Location independence, Physical security of data centre locations
Some example of SaaS providers are: Google Apps: provides web-based office tools such as e-mail, calendar and document management	Some PaaS examples are: Microsoft Azure Services Platform: provides users with on-demand compute and storage services as well as a	Example: Amazon Elastic Compute Cloud (EC2): provides users with a special virtual machine (AMI) that can be deployed and run on the EC2 infrastructure

	development platform based on Windows Azure	
--	--	--

LITERATURE SURVEY ON CLOUD COMPUTING RESEARCH

Cloud computing is a rapidly evolving field, and there has been a significant amount of research in this area.

Query Optimization: Database query progress predictors [2] solve a performance prediction problem similar to Ernest.

Query optimization is an essential research area in cloud computing, as it enables the efficient processing of queries on large-scale datasets. Here is an overview of some of the key research in this area:

Query Processing: Query processing is a critical component of cloud computing, as it enables the efficient processing of queries on large-scale datasets.

Query Optimization: Query optimization is a key technique for improving the performance of cloud-based systems.

Query Scheduling: Query scheduling is critical for ensuring optimal performance in cloud-based systems.

Data Partitioning: Data partitioning is essential for optimizing query performance on cloud-based systems.

Query Language Design: Query language design is critical for improving the performance of cloud-based systems. Researchers have developed various query languages, including SQL, NoSQL, and NewSQL. These languages enable the efficient processing of queries and the optimization of query performance.

Overall, query optimization is an important research area in cloud computing, as it enables the efficient processing of queries on large-scale datasets. Researchers have developed various techniques, algorithms, and languages to optimize query performance, and these techniques are essential for improving the reliability and efficiency of cloud computing.

Query optimization is an important research area in cloud computing, as it involves improving the efficiency of query processing and reducing the cost of executing queries in a cloud environment. Here are some recent studies on query optimization in cloud computing:

"Optimizing SQL Queries in Cloud Computing Environments" by S. Patel, H. Patel, and S. Patel.

This paper proposes a query optimization technique that uses machine learning algorithms to identify the most efficient execution plan for a given SQL query in a cloud environment. The authors demonstrate the effectiveness of their approach on a variety of workloads and show that it can significantly reduce query execution time and cost.

"A Machine Learning Approach for Query Optimization in Cloud Databases" by Z. Zang, Y. Wang, and Y. Xu.

This paper proposes a machine learning approach for query optimization in cloud databases that uses a neural network to predict query execution time. The authors demonstrate that their approach can significantly reduce query execution time and improve the scalability of the system.

Overall, these recent studies demonstrate that query optimization in cloud computing remains an active area of research, with various techniques being developed to improve the efficiency and reduce the cost of executing queries in cloud database systems. The adoption of machine learning and multi-objective optimization approaches are also gaining traction in this field.

Performance Prediction. Performance prediction in cloud computing research is an important area of study that focuses on accurately estimating the performance of cloud-based applications and services. This helps cloud providers optimize their resource utilization and meet Service Level Objectives (SLOs) or deadlines.

There have been several recent efforts to model job performance in datacenters to support Service Level Objectives (SLOs) or deadlines. Here are some examples of techniques proposed in recent studies:

Jockey and ARIA: These techniques use historical traces and dynamically adjust resource allocations in order to meet deadlines. Jockey optimizes resource allocation to reduce job completion times, while ARIA uses a stochastic approach to predict job completion times and dynamically adjusts resource allocations to meet deadlines.

Ernest: This technique builds a model with no historical information and tries to minimize the amount of training data required. Ernest captures computation and communication characteristics and uses high-level features that are framework-independent.

Bazaar: This technique proposes techniques to model the network utilization of MapReduce jobs by using small subsets of data.

MRTuner: This technique models MapReduce jobs at a very fine granularity and sets optimal values for options like memory buffer sizes.

Quasar: This scheduling framework tries to estimate the scale-out and scale-up factor for jobs using the progress rate of the first few tasks.

There are several techniques and approaches used for performance prediction in cloud computing research. Some of the commonly used techniques include statistical modeling, machine learning, deep learning, and predictive analytics. Statistical modeling involves using mathematical models and algorithms to predict performance based on historical data. Machine learning involves using algorithms that can learn from data to make predictions about future performance. Deep learning involves using neural networks to analyze large amounts of data and make predictions. Predictive analytics involves using statistical methods to identify patterns and trends in data and make predictions based on those patterns.

Recent studies have focused on improving performance prediction in cloud computing research through the use of these techniques. For example, some studies have used machine learning algorithms to predict resource demand and improve resource allocation efficiency. Others have used predictive analytics to identify patterns in data that can help optimize resource utilization.

There is also ongoing research focused on developing new approaches for performance prediction in cloud computing. This includes the use of big data analytics, artificial intelligence, and other emerging technologies. Additionally, there is a growing focus on developing techniques for real-time performance prediction, which can help cloud providers quickly identify and respond to performance issues.

Overall, performance prediction is an important area of research in cloud computing that plays a critical role in optimizing resource utilization and meeting Service Level Objectives (SLOs) or deadlines. As cloud computing continues to grow in importance, there is likely to be increasing focus on developing new and more effective techniques for performance prediction.

Performance prediction in cloud computing is a crucial area of research that aims to accurately estimate the performance of cloud-based applications and services. Here are some recent studies that have focused on performance prediction in cloud computing:

"Performance Prediction for Cloud Computing: A Review" by Z. Wei, S. Qi, Q. Peng, and Y. Guo.

This paper provides a comprehensive review of performance prediction techniques in cloud computing. The authors discuss various approaches to performance prediction, including statistical modeling, machine learning, and deep learning, and highlight their advantages and limitations. They also discuss the challenges of performance prediction in cloud computing and identify future research directions.

"Performance Prediction of Cloud Applications Using Machine Learning Techniques" by N. Mohamed et al.

This paper proposes a machine learning-based approach to predict the performance of cloud applications. The authors evaluate their approach on a real-world dataset and show that it can accurately predict performance metrics such as response time and throughput.

Overall, these recent studies demonstrate the importance of performance prediction in cloud computing and the potential of machine learning and other predictive techniques to improve resource utilization and meet performance targets.

OVERVIEW OF STATE-OF-THE-ART CLOUD COMPUTING LITERATURE

In this section a brief discussion is presented on recently published work on cloud computing.

CherryPick: Adaptively Unearthing the Best Cloud Configurations for Big Data Analytics.

CherryPick is a system that leverages Bayesian Optimization to build performance models for various applications, and the models are just accurate enough to distinguish the best or close-to-the-best configuration from the rest with only a few tests runs. The experiments conducted on five analytic applications in AWS EC2 showed that CherryPick has a 45-90% high chance of finding the optimal or near-optimal configuration, which can result in significant cost savings compared to existing solutions. The search cost can be reduced by up to 75% in some cases, which makes CherryPick an effective solution for optimizing the cloud configuration for big data analytics workloads.

CherryPick is a research paper that proposes a framework for adaptive cloud configuration selection for big data analytics workloads. The paper addresses the problem of choosing the optimal cloud configuration for big data workloads, which can involve a large number of parameters that affect performance, such as memory size, CPU speed, and storage capacity. The authors argue that manually tuning these parameters can be time-consuming and error-prone, and that automated approaches can be limited by the lack of a comprehensive and accurate performance model.

To address these challenges, the CherryPick framework proposes an adaptive approach that selects the best cloud configuration based on real-time performance monitoring of the workload. The framework uses a machine learning model to predict the performance of different cloud configurations and selects the optimal configuration based on these predictions. The authors demonstrate the effectiveness of the CherryPick framework using a real-world big data analytics workload on Amazon Web Services (AWS) and show that it can outperform state-of-the-art cloud configuration selection approaches by up to 30%.

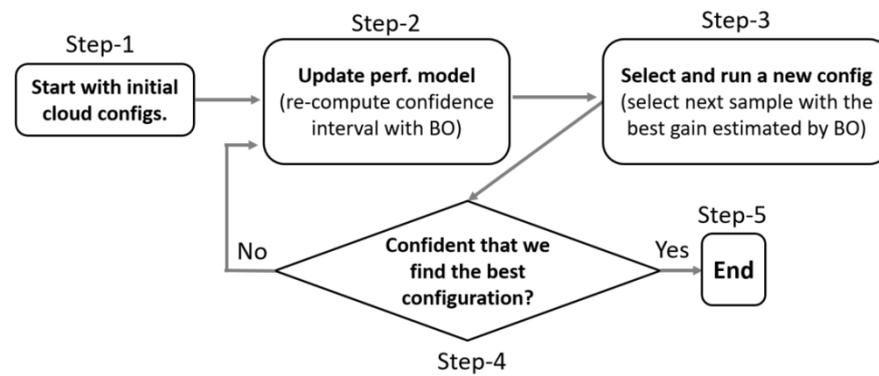


Fig. 4. CherryPick workflow [2]

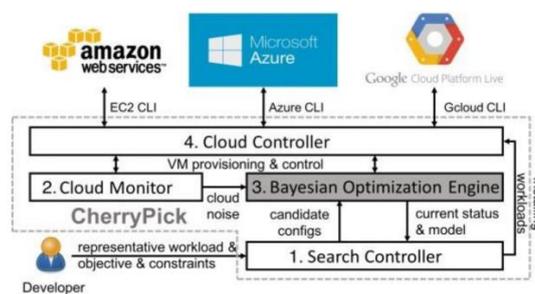


Fig. 5. Architecture of CherryPicks implementation [2]

The implementation details of CherryPick as shown in Fig. 5. It has four modules: 1. *Search Controller*: Search Controller orchestrates the entire cloud configuration selection process; 2. *Cloud Monitor*: Cloud Monitor runs benchmarking workloads of Big Data defined by CherryPick on different clouds; 3. *Bayesian Optimization Engine*: Bayesian Optimization Engine is built on top of Spearmint which is an implementation of BO in Python. 4. *Cloud Controller*: Cloud Controller is an adaptation layer which handles the heterogeneity to control the clouds.

CONCLUSION

Cloud computing has recently become an attractive paradigm for managing and providing Services over the Internet. The development of cloud computing is rapidly changing the landscape of information technology and will ultimately make the long-term promise of utility computing a reality. However, despite the significant advantages of cloud computing, modern technologies are not developed enough to realize their full potential. Many key issues in this field, including automatic resource allocation, and security management, have begun to attract the attention of the research community.

In this article, I reviewed the current state of cloud computing, covering their key concepts, architectural projects, outstanding characteristics, key technologies, and research areas. Since the development of cloud computing technology is still in its early

stages, I hope that this work will allow us to better understand the problems of cloud computing design and pave the way for further research in this area.

REFERENCES

1. URL: <https://www.sitech.me/blog/advantages-disadvantages-of-cloud-computing> (date of application: 17.03.2023)
2. URL: <https://shivaram.org/publications/cherrypick-nsdi17.pdf> (date of application: 17.03.2023)
3. Mell P., Grance T. The NIST definition of cloud computing // National Institute of Standards & Technology Gaithersburg MD United States. – 2011
4. URL: <https://www.dragon1.com/concepts/cloud-computing> (date of application: 17.03.2023)
5. Morton K., Balazinska M., Grossman D. Paratimer: a progress indicator for mapreduce dags // In Proceedings of the 2010 ACM SIGMOD International Conference on Management of data ACM. – 2010. – pages 507–518.
6. URL: Amazon web services, aws.amazon.com (date of application: 17.03.2023)
7. URL: Windows azure, www.microsoft.com/azure (date of application: 18.03.2023)
8. S. Patel, H. Patel, S. Patel "Optimizing SQL Queries in Cloud Computing Environments" research paper// Journal of Cloud Computing: Advances, Systems and Applications. – 2017.
9. Z. Zang, Y. Wang, and Y. Xu "A Machine Learning Approach for Query Optimization in Cloud Databases" research paper// Journal of Computational Science. – 2016.
10. Z. Wei, S. Qi, Q. Peng, and Y. Guo "Performance Prediction for Cloud Computing: A Review"// IEEE Transactions on Services Computing. – 2020.
11. URL: <https://shivaram.org/publications/cherrypick-nsdi17.pdf> (date of application: 18.03.2023)
12. Wittig A., Wittig M. Amazon Web Services in Action 2nd Edition// Manning. – 2018. 528 pages.
13. Dotson Ch. Practical Cloud Security: A Guide for Secure Design and Deployment 1st Edition// O'Reilly Media. – 2019. 194 pages.

MODERN METHODS OF DATA ANALYSIS

Abdullayeva Zh.T., Seksenova Zh.M.

Astana International University, Astana, Republic of Kazakhstan,
seksenova.zhuldyz@bk.ru

Abstract. Data analysis is a crucial process for extracting insights from large and complex datasets. In this article, we provide a comprehensive overview of modern methods of data analysis. We begin by discussing the importance of data analysis and its applications in various fields, including business, healthcare, and scientific research. We explore how these methods can be used to uncover patterns, make predictions, and identify trends in data. We also discuss some of the challenges and limitations of data analysis, including the potential for biased results and the need for careful data preparation and cleaning. Overall, this article is a valuable resource for anyone interested in understanding the power of data analysis and how it can be used to gain insights into complex problems. By exploring the latest methods and trends in data analysis, we hope to inspire readers to apply these techniques in their own work and to contribute to the continued advancement of this exciting field.

Keywords: Data Analysis, modern, methods, Big data, Machine Learning, Metadata

INTRODUCTION

In today's digital age, the sheer amount of data available is staggering, and traditional methods of analysis can quickly become overwhelmed. As a result, modern methods of data analysis have emerged to help researchers and businesses make sense of this data deluge. The objectives of this article are to provide a brief overview of some of the most popular modern methods of data analysis and to demonstrate how they can be applied to real-world problems. Specifically, we will explore the use of machine learning algorithms, artificial intelligence, and big data analytics in the context of data analysis. Our research problem is to determine which of these methods are most effective for different types of data and analytical challenges. The significance of this study is twofold: first, it will provide a theoretical framework for understanding the modern methods of data analysis, and second, it will offer practical insights into how these methods can be applied to real-world problems.

In the era of big data, the need for modern methods of data analysis has never been more urgent. With the ever-increasing amount of data being generated and collected, there is a growing demand for advanced techniques to extract insights and make informed decisions. Traditional methods of data analysis, such as statistical methods and regression analysis, are no longer sufficient in dealing with the complexity and volume of today's data. Instead, modern methods of data analysis, such as machine learning,

natural language processing, graph analytics, time series analysis, and data visualization, have emerged as essential tools for data scientists and analysts.

Scientists' opinions on modern methods of data analysis can vary based on their specific field of study and research focus. However, there are some general trends in their opinions. Some scientists view modern data analysis methods, such as machine learning and big data analytics, as powerful tools that can help them make sense of complex data sets and discover new insights. For example, Leo Breiman has argued that machine learning techniques like random forests and boosting are superior to traditional statistical methods in many applications, because they can handle complex, high-dimensional data and non-linear relationships. However, he has also called for more research into the interpretability and transparency of machine learning models. Geoffrey Hinton has argued that deep learning is the best way to achieve artificial intelligence that can understand natural language and perceive the world like humans do. However, he has also expressed concern about the potential misuse of AI for harmful purposes, and has called for regulation and ethical guidelines to guide its development. John Tukey emphasized the importance of exploratory data analysis in uncovering unexpected patterns and relationships in data, and advocated for the use of graphical methods to communicate findings. He also criticized the over-reliance on statistical tests and p-values in scientific research, arguing that they often lead to oversimplified and misleading conclusions.

Others, however, may have concerns about the reliability and interpretability of these methods. For example, some worry that algorithms used in machine learning may introduce bias or overlook important information, leading to incorrect conclusions. One area of concern is the potential for bias in machine learning algorithms. Because these algorithms are trained on large amounts of data, they may learn and reinforce patterns of bias that exist in the data, leading to discriminatory outcomes. Judea Pearl has emphasized the importance of causal inference in data analysis, arguing that statistical correlations alone are not sufficient for making causal claims about the relationship between variables. He has also expressed skepticism about some machine learning techniques that do not take into account causal relationships between variables.

Additionally, some scientists may prefer more traditional statistical methods, which they feel are more transparent and easier to interpret. Bradley Efron has expressed enthusiasm for the potential of computational methods to revolutionize statistical inference, and has advocated for their wider use in scientific research. He has also called for increased collaboration between statisticians and other fields, to ensure that statistical methods are being used appropriately and effectively.

Overall, while there are concerns about the potential limitations and challenges associated with modern data analysis methods, many scientists recognize their potential benefits for advancing scientific knowledge and solving complex problems.

MATERIALS AND METHODS

Modern methods of data analysis refer to the latest techniques and approaches used to extract insights and knowledge from data. Some of the modern methods of data analysis are:

Machine Learning. Machine learning is one of the most important modern methods of data analysis. It is a subset of artificial intelligence (AI) that focuses on developing algorithms and models that can learn from data and make predictions or decisions without being explicitly programmed to do so. Machine learning has numerous applications in fields such as healthcare, finance, transportation, and more. The basic idea behind machine learning is to identify patterns and relationships in data that can be used to make predictions or classify new data. There are three main types of machine learning: supervised learning, unsupervised learning, and reinforcement learning.

Supervised learning involves training a machine learning model on labeled data, where the outcomes of interest are known. The model learns to make predictions based on the features or attributes of the data. For example, a supervised learning model could be trained to predict whether an email is spam or not based on the text of the email and other features.

Unsupervised learning, on the other hand, involves training a model on unlabeled data, where the outcomes are not known. The goal of unsupervised learning is to identify patterns and relationships in the data without a specific goal in mind. Clustering and dimensionality reduction are two common unsupervised learning techniques.

Reinforcement learning involves training a model to make decisions based on feedback from its environment. The model learns to take actions that maximize a reward signal, such as a score or a profit. Reinforcement learning is commonly used in robotics, gaming, and other areas where agents need to make decisions in complex, dynamic environments.

Overall, machine learning has revolutionized the field of data analysis by allowing researchers to analyze and make predictions based on complex, high-dimensional data. However, as mentioned earlier, there are concerns about the reliability, interpretability, and ethical implications of machine learning models, which require ongoing research and development.

Deep Learning. Deep learning is a subset of machine learning that uses artificial neural networks to process and analyze large and complex datasets. The name "deep" refers to the depth of the neural network, which typically consists of multiple layers of interconnected nodes. Deep learning algorithms are designed to learn from data in a way that is similar to the way the human brain processes information. The neural network is trained on a large dataset, with each layer of nodes learning to extract and process features from the data. As the network processes more data, it becomes increasingly

accurate at making predictions or classifications. Deep learning has been used to achieve impressive results in a wide range of applications, including image and speech recognition, natural language processing, and even playing games like Go and chess at a world-class level. One of the key benefits of deep learning is its ability to automatically learn features from raw data, without the need for manual feature engineering. This makes it particularly well-suited for processing large and complex datasets, where manual feature engineering would be impractical or impossible. However, one of the main challenges with deep learning is its high computational requirements. Deep neural networks require significant computing power to train, often requiring specialized hardware like GPUs or TPUs. Additionally, the large number of parameters in deep neural networks can make them prone to overfitting, where the model becomes too complex and performs well on the training data but poorly on new data.

Deep Learning and other types of machine learning algorithms: differences and relate. Deep learning is a subset of machine learning, so there is a close relationship between the two. However, there are some key differences between deep learning and other types of machine learning algorithms.

Machine learning algorithms are designed to automatically learn patterns and relationships in data and use these to make predictions or decisions. They typically involve the use of mathematical models, such as linear regression, decision trees, or support vector machines. Machine learning algorithms are often used for structured data, such as numerical data in spreadsheets or databases.

Deep learning, on the other hand, is a specific type of machine learning algorithm that uses artificial neural networks to process and analyze large and complex datasets. The neural network consists of multiple layers of interconnected nodes, each learning to extract and process features from the data. Deep learning algorithms are often used for unstructured data, such as images, video, and text. One key difference between deep learning and other types of machine learning algorithms is their ability to automatically learn features from raw data. This eliminates the need for manual feature engineering, which can be time-consuming and error-prone. Another difference between deep learning and other types of machine learning algorithms is their ability to handle large and complex datasets. Deep learning algorithms are designed to scale to large datasets, making them well-suited for tasks like image recognition and natural language processing.

Despite these differences, deep learning and other types of machine learning algorithms share some commonalities. Both involve the use of mathematical models to learn patterns and relationships in data, and both require large datasets for training.

To give an example, let's consider the example of image recognition. With traditional machine learning algorithms, an engineer would need to manually identify features in the images, such as lines, edges, and shapes, and then use these features to

train a model to recognize specific objects in the images. This process can be time-consuming and error-prone, especially when dealing with large and complex datasets. In contrast, with deep learning algorithms, the neural network automatically learns to identify and extract features from the raw image data. Each layer of the neural network learns to recognize increasingly complex patterns and relationships in the images, allowing the network to make highly accurate predictions about the objects in the images. For example, a deep learning model trained on a large dataset of cat and dog images might learn to identify key features of each animal, such as the shape of their ears or the pattern of their fur. Once trained, the model could then be used to classify new images as either cats or dogs, based on the presence of these features. This ability to automatically learn features from raw data is a key advantage of deep learning over traditional machine learning algorithms, and has enabled breakthroughs in areas such as computer vision and natural language processing.

Overall, deep learning is a powerful modern method of data analysis that has achieved impressive results in a wide range of applications. While it is a subset of machine learning, it has some unique features that make it particularly well-suited for processing large and complex datasets of unstructured data.

Big Data Analytics. Big data is another important modern method of data analysis that has emerged in recent years. It refers to extremely large, complex, and diverse data sets that cannot be processed and analyzed using traditional methods of data analysis. The emergence of big data is driven by the increasing availability and variety of digital data sources, such as social media, mobile devices, sensors, and more. These data sources generate huge amounts of data that can be used to gain insights and make predictions about human behavior, markets, and more. The challenge with big data is that it requires specialized tools and techniques for processing, storing, and analyzing the data. Traditional methods of data analysis, such as statistical inference and hypothesis testing, may not be suitable for big data due to the volume, velocity, and variety of the data. One common approach to analyzing big data is to use distributed computing platforms like Apache Hadoop or Apache Spark, which allow for parallel processing of large datasets across multiple servers or nodes. Another approach is to use *machine learning* algorithms that are specifically designed to handle big data, such as deep learning and reinforcement learning. The insights gained from big data analysis can have significant practical applications in areas like healthcare, business, marketing, and more. For example, big data analysis can be used to predict consumer behavior, improve patient outcomes, optimize supply chain management, and more.

However, as with any modern method of data analysis, there are concerns about the ethical implications of big data analysis, particularly around issues of privacy and security. Overall, big data represents a powerful tool for data analysis, but requires ongoing research and development to ensure its responsible and ethical use.

Big data and Machine learning: differences and relate. Big data and machine learning are related but distinct modern methods of data analysis. While they share some commonalities, they are used for different purposes and require different approaches.

Big data refers to extremely large, complex, and diverse data sets that cannot be processed and analyzed using traditional methods of data analysis. The primary goal of big data analysis is to identify patterns and relationships in the data that can be used to gain insights and make predictions.

Machine learning, on the other hand, is a subset of artificial intelligence that focuses on developing algorithms and models that can learn from data and make predictions or decisions without being explicitly programmed to do so. The primary goal of machine learning is to create models that can make accurate predictions or decisions based on data.

While big data and machine learning are distinct, they are often used together to solve complex problems. Big data provides the raw material for machine learning algorithms, which can then be trained on the data to create accurate models. Machine learning algorithms can also be used to process and analyze big data sets, as traditional methods of data analysis may not be suitable. One key difference between big data and machine learning is the type of data they are used for. Big data typically refers to unstructured data, such as text, images, and video, while machine learning is often used for structured data, such as numerical data in spreadsheets or databases.

To give an example, let's say a company wants to analyze customer feedback to identify areas for improvement in their products and services. They have a large dataset consisting of customer reviews, social media posts, and other unstructured data. This dataset is too large and complex to be analyzed using traditional methods of data analysis, so they turn to big data analysis. Using big data techniques, the company is able to process and analyze the customer feedback dataset to identify common themes and sentiments expressed by customers. However, the company wants to take their analysis a step further and develop models to predict customer behavior and sentiment. To achieve this, they turn to machine learning algorithms. Using the processed and analyzed big data as training data, they develop a machine learning model that can accurately predict customer sentiment and behavior based on new data. With this model, the company is able to not only gain insights from their customer feedback data, but also make accurate predictions about customer behavior and sentiment. They can then use this information to improve their products and services and better meet the needs of their customers. In this example, big data is used to process and analyze the large and complex customer feedback dataset, while machine learning is used to develop accurate models that can make predictions based on this data. Together, big data and machine learning enable the company to gain valuable insights and make data-driven decisions.

Overall, big data and machine learning are complementary modern methods of data analysis that can be used together to gain insights and make predictions about complex systems. While they are distinct, they share some commonalities and require ongoing research and development to ensure their responsible and ethical use.

Data Mining. Data mining is a modern method of data analysis that involves the process of discovering patterns, correlations, and insights from large datasets. It is a subfield of machine learning that focuses on exploratory data analysis and unsupervised learning. The goal of data mining is to extract useful and actionable information from data, which can be used for a variety of purposes, such as decision making, predictive modeling, and optimization. Data mining techniques can be applied to many different types of data, including structured data, such as numerical and categorical data, and unstructured data, such as text and images.

Data mining techniques can be broadly categorized into four main types:

Clustering: This involves grouping similar objects together based on their characteristics or attributes. It is commonly used for customer segmentation, anomaly detection, and image segmentation.

Classification: This involves assigning objects to predefined categories based on their characteristics or attributes. It is commonly used for image and text classification, fraud detection, and spam filtering.

Association rule learning: This involves discovering relationships between variables in a dataset, such as items frequently purchased together in a shopping basket. It is commonly used for market basket analysis, recommendation systems, and fraud detection.

Regression: This involves predicting the value of a continuous variable based on other variables in a dataset. It is commonly used for forecasting, risk analysis, and trend analysis.

To give an example, let's consider the example of fraud detection in financial transactions. Data mining techniques can be applied to large datasets of financial transactions to identify patterns and anomalies that may indicate fraudulent activity. For example, clustering techniques can be used to group transactions with similar characteristics, such as the location and amount of the transaction, and identify clusters that have a higher likelihood of fraud. Classification techniques can be used to develop predictive models that assign a probability of fraud to each transaction based on its characteristics, such as the type of transaction and the time of day. These models can be used to flag transactions that have a high probability of fraud for further investigation. Association rule learning techniques can be used to identify relationships between transactions that may indicate fraudulent activity, such as a series of small transactions that add up to a large amount or transactions that occur at unusual times or locations.

Finally, regression techniques can be used to predict the likelihood of future fraudulent activity based on historical data, allowing financial institutions to proactively implement measures to prevent fraud. Data mining techniques have been shown to be highly effective in detecting fraudulent activity in financial transactions and have been widely adopted by financial institutions and law enforcement agencies around the world.

Data mining is a powerful method of data analysis that has been used in a wide range of applications, including marketing, finance, healthcare, and scientific research. It is particularly useful for identifying patterns and relationships in large and complex datasets, which may not be apparent through simple data exploration techniques.

Metadata. Metadata is a modern method of data analysis that involves the collection and analysis of information about other data. Metadata can provide important context and information about data, such as when and where it was created, its format, its quality, and its relevance to other data. Metadata can be collected and analyzed using a variety of techniques, including manual data entry, automated data extraction, and data mining. Metadata can be used for a variety of purposes, such as data management, data discovery, and data integration.

One example of metadata in action is in the field of search engine optimization (SEO). Search engines use metadata, such as page titles, descriptions, and keywords, to help determine the relevance and ranking of web pages in search results. By optimizing metadata, webmasters can improve the visibility and traffic of their websites. Another example of metadata in action is in the field of scientific research. Metadata can be used to provide important context and information about research data, such as the methodology used to collect the data, the instruments used, and the units of measurement. This information can help other researchers to understand and reproduce the results of the study. Metadata can also be used to facilitate data sharing and interoperability between different systems and applications. By providing a common set of metadata standards, different data systems can communicate and share data more easily, improving data quality and reducing duplication of effort.

Overall, metadata is a powerful tool for data analysis that can provide important context and information about data, improving its usefulness and value.

Real-time data. Real-time data analysis refers to the process of analyzing data as it is generated, rather than after it has been collected and stored. It involves the use of technologies and techniques that enable data to be processed and analyzed in near real-time or real-time. Real-time data analysis has become increasingly important in many fields, including finance, healthcare, transportation, and manufacturing.

To give an example, Health monitoring and disease surveillance: Healthcare providers and public health agencies use real-time data analysis to monitor and respond to disease outbreaks and other health emergencies. By analyzing data from electronic

health records, social media, and other sources in real-time, health officials can identify trends and patterns and respond quickly to contain outbreaks.

For example, during the COVID-19 pandemic, public health agencies have been using real-time data analysis to monitor the spread of the virus and identify areas of high transmission. By analyzing data on confirmed cases, hospitalizations, and deaths in real-time, officials have been able to make informed decisions about lockdowns, social distancing measures, and other interventions. Real-time data analysis is also being used in healthcare settings to monitor patients and predict health outcomes. By analyzing vital signs, lab results, and other data in real-time, healthcare providers can detect early warning signs of complications and provide timely interventions to improve outcomes.

Overall, real-time data analysis is becoming increasingly important as organizations seek to gain real-time insights from data and make informed decisions in a timely manner. It requires the use of advanced technologies and techniques such as stream processing, real-time analytics, and machine learning.

Data Visualization. Data visualization is a modern method of data analysis that involves the use of visual representations, such as charts, graphs, and maps, to communicate complex data in a more easily understandable and engaging way. By transforming raw data into visual formats, data visualization can help people quickly identify patterns, trends, and outliers, and make better decisions based on the insights gained.

To give an example, Businesses use data visualization to gain insights into their operations and make informed decisions. For example, a company may use a dashboard that displays key performance indicators (KPIs) in a visual format, such as line charts or bar graphs, to track sales, revenue, and other metrics.

Another example of how data visualization. Data visualization is also being used to improve education and e-learning. For example, educators can use visualizations to help students better understand complex concepts and identify areas where they need to improve. Interactive visualizations can also be used to create more engaging learning experiences, allowing students to explore data and interact with visualizations in real-time. In addition, data visualization can be used to track and analyze student performance and engagement. Educators can use dashboards and other visualizations to monitor metrics such as attendance, test scores, and participation rates, and identify areas where students may be struggling. This can help educators to provide targeted interventions and support to improve student outcomes.

Overall, data visualization is a powerful tool for exploring and communicating data. It can help people better understand complex data sets, identify trends and patterns, and make better decisions based on the insights gained.

Modern methods of data analysis have revolutionized the way we process and interpret data. With the advent of technologies such as big data, machine learning, deep learning, data mining, real-time data, metadata, and data visualization, we are able to make sense of vast amounts of data and gain insights that would have been impossible to uncover with traditional methods.

CONCLUSION

In conclusion, modern data analysis methods have become increasingly important in today's world of big data. With the exponential growth of data, traditional methods of analysis have become insufficient in providing actionable insights. Modern data analysis methods such as machine learning, deep learning, big data analytics, predictive analytics, data mining, real-time data analytics, metadata analysis, and data visualization have allowed us to process and analyze vast amounts of data quickly and accurately. By leveraging these methods, we can discover patterns and insights that would be otherwise hidden, make informed decisions, and ultimately enhance productivity and efficiency. As data continues to grow, modern data analysis methods will only become more essential in our pursuit of knowledge and innovation.

While these modern methods of data analysis have great potential, they are not without their limitations and challenges. For example, concerns about data privacy, bias, and interpretability remain important issues that must be addressed. Nevertheless, as technology continues to advance, we can expect to see further improvements in the capabilities and applications of modern methods of data analysis, leading to even greater insights and discoveries in a wide range of fields.

REFERENCES

1. Bruce P., Bruce A. Practical Statistics for Data Scientists: 50 Essential Concepts// O'Reilly Media. – 2019. 363 pages.
2. McKinney W. "Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython" 2nd Edition// O'Reilly Media. – 2020. 548 pages
3. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems// O'Reilly Media. – 2019. 856 pages.
4. Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques//Morgan Kaufmann Publishers. – 2019. 740 pages.

ТҮРКІСТАН ОБЛЫСЫНЫҢ БИОКЛИМАТТЫҚ ЖАҒДАЙЫН БАҒАЛАУ

Оралбекова Назерке Асанқызы

Ғылыми жетекші: *Байшолманов Сакен Советұлы*
Астана халықаралық университетінің 2 курс магистранты
Астана қ., Қазақстан
n.oralbekova@inbox.ru

Аннотация: Мақалада Түркістан облысы климатының адамдардың тұрмыс-тіршілігіне қолайлығы бағаланған. Зерттеу нәтижесінде адамдардың тұрмыс-тіршілігі үшін Түркістан облысының жазық жерлерінің жазда ыстық қолайсыз, ал таулы жерлерінің – жылы қолайлы екені анықталды. Ал қыс маусымы оның солтүстік шетінде қолайсыздау, басқа жерлерінде қолайлы болады. Жалпы алғанда Түркістан облысының климаты адамдардың тұрмыс-тіршілігі, денсаулығы және жұмыс қабілеттілігі үшін жеткілікті түрде қолайлы деп санауға болады.

Түйін сөздер: ауа температурасы, ауа ылғалдылығы, жел жылдамдығы, биоклиматтық индекстер.

КІРІСПЕ

Биоклиматтық жағдай – адам ағзасына, тұрмыс-тіршілігіне әсер ететін климаттық жағдай. Климаттың адамдар үшін қолайлығын арнайы биоклиматтық индекстер арқылы бағалайды. Биоклиматтық индекстер физикалық тұрғыда қоршаған ортаның жылулық ерекшеліктерін кешенді сипаттайтын метеорологиялық көрсеткіштер болып табылады. Ауа температурасы, ауа ылғалдылығы, жел жылдамдығы сияқты метеорологиялық көрсеткіштерді адамның жылуды, не салқынды сезінуімен байланыстырады. Биоклиматтық индекстер жыл айлары бойынша есептеледі және арнайы критерийлермен бағаланады. Бұл мақалада Түркістан облысы аумағының биоклиматтық жағдайы ең жылы және ең салқын айлар бойынша бағаланған.

Түркістан облысы Қазақстанның оңтүстігінде орналасқан. Орталығы – Түркістан қаласы. Солтүстігінде Ұлытау, шығысында Жамбыл, батысында Қызылорда обыстырымен, оңтүстігінде Өзбекстан Республикасымен шектеседі. Алып жатқан жер аумағы 117,3 мың км² [1]. Географиялық тұрғыдан облыс жер бедерінің әртүрлігімен ерекшеленеді. Жер бедері тегіс даладан орта және биік

тауларға дейін өзгереді. Бұл рельефтің ерекшелігі климаттың құрылуына да әсерін тигізеді.

ДЕРЕКТЕР МЕН ЗЕРТТЕУ ӘДІСТЕРІ

Зерттеу барысында Қазақстан Республикасы Экология және табиғи ресурстар министрлігі «Қазгидромет» республикалық мемлекеттік кәсіпорны метеорологиялық станцияларының (МС) 1991-2020 жылдар аралығындағы деректері пайдаланылды.

Негізгі биоклиматтық индекстерге жатады:

- Тиімді температура (ТТ);
- Эквивалентті – тиімді температура (ЭТТ);
- Бодман бойынша қаталдық индексі (S);
- Радиациялық эквивалентті – тиімді температура (РЭТТ);
- Қалыпты эквивалентті – тиімді температура (ҚЭТТ);
- Биологиялық белсенді температура (ББТ);
- Келтірілген температура (t келт.).

Биоклиматтық индекстердің теңдеулері негізінен ауа температурасы мен ылғалдылығын, жел жылдамдығын және күн радиациясын қамтиды [2-8]:

Тиімді температура (ТТ) – желсіз тыныштықтағы ауа температурасы [2]:

$$ТТ = t - 0,4(t - 10) (1 - f / 100), \quad (1)$$

мұнда: f – ауаның салыстырмалы ылғалдылығы, %;

t – ауа температурасы, °С.

ТТ сәйкес климаттық жайлылықты бағалау үшін 1-кестеде келтірілген критерийлер пайдаланылады.

Кесте 1. Климаттың жайлылығын ТТ арқылы бағалау критерийлері

ТТ, °С	Жылу сезіну	Жылулық жүктеме
30 жоғары	өте ыстық (дисконфорт)	күшті
30-24	ыстық (жылы субкомфорт)	орташа
24-18	жылы (жылы комфорт)	комфортты
18-12	орташа жылы (жылы комфорт)	
12-6	салқын (салқын субкомфорт)	орташа
6-0	орташа салқын (салқын дисконфорт)	
0 – минус 12	суық	
минус 12 – минус 24	өте суық	үсік шалу қаупі жоғары
минус 24 – минус 30	өте қатты суық	үсік шалу қаупі өте жоғары
ниже минус 30	өте қатты суық	қатып қалу қаупі өте жоғары

Эквивалентті-тиімді температура (ЭТТ) – желдің әсерін және ауа ылғалдылығын ескеретін жылулық сезімталдық көрсеткіші [2]:

$$\text{ЭТТ} = 37 - \frac{37 - t}{0,68 - 0,0014f + \frac{1}{1,76 + 1,4v^{0,75}}} - 0,29t\left(1 - \frac{f}{100}\right), \quad (2)$$

мұнда t – ауа температурасы, °С;

f - салыстырмалы ылғалдылық, %;

v - жел жылдамдығы, м/с.

ЭТТ көлеңкедегі адамның жылу сезімін немесе киінген адамның жылу сезімін сипаттайды. Бұл көрсеткіш жылы диапазонға жақсы сәйкес келеді, салқын диапазоны үшін қанағаттанарлық, ал суық диапазон үшін оны шамалау критерийі ретінде қарастыруға болады. Адамдардың көпшілігі үшін ауа температурасы 22,0-23,0 °С және салыстырмалы ылғалдылық 56 % қолайлы, бұл 18 ° ЭТТ-ға жақын. ЭТТ мәндеріне байланысты бағаланады:

- 1-17°С – салқын;
- 17-21°С – жылы;
- 21°С жоғары – ыстық.

Бодман қатаңдық индексі (S) [3]:

$$S = (1 - 0,04t)(1 + 0,27v), \quad (3)$$

мұнда S – қатаңдық көрсеткіші (балл);

t – ауа температурасы (°С);

v – жел жылдамдығы, м/с.

S арқылы қыстың қатаңдығын бағалағанда келесі критерийлер қолданылады:

- S = 1 – қыс жұмсақ;
- S = 1-2 – қыс әлсіз қатаң;
- S = 2-3 – қыс орташа қатаң;
- S = 3-4 – қыс қатаң;
- S = 4-5 – қыс өте қатаң;
- S = 5-6 – қыс шексіз қатаң;
- S > 6 – қыс өте шексіз қатаң;

Радиациялық эквивалентті-тиімді температура (РЭТТ) [4]:

$$PЭТТ = 125 \lg[1 + 0,02t + 0,001(t - 8)(f - 60) - 0,45(33 - t)\sqrt{v} + 185B], \quad (4)$$

мұнда t – ауа температурасы, °С;

f – ауаның салыстырмалы ылғалдылығы, %;

v – желдің жылдамдығы, м/с;

B – жер бетімен жұтылатын күн радиациясы, кВт/м².

РЭТТ-ні келесі формула арқылы да есептеуге болады [5]:

$$РЭТТ = 0,83ЭТТ + 12 \text{ } ^\circ\text{C}, \quad (5)$$

РЭТТ ең жақсы көрсеткіш ретінде сипатталады. РЭЭТ бойынша бағаланады:

- салқын дискомфорт: 17°C төмен;
- салқын субкомфорт: 17-21°C;
- жылы комфорт: 21–27°C;
- жылы субкомфорт: 27-32°C;
- ыстық дискомфорт: 32°C жоғары.

5) Қалыпты эквивалентті - тиімді температура (ҚЭТТ) - киінген адамға желдің әсерін ескере отырып жылулық сезімталдық көрсеткіші [6]:

$$ҚЭТТ = 0,8ЭТТ + 7 \text{ } ^\circ\text{C}, \quad (6)$$

ҚЭЭТ мәліметтері бойынша, жайлылық аймағы киім кимеген адам үшін 17,2-21,7 °C, ал киінген адам үшін 16,7-20,6 °C аралығында болады. Бұл шектен төмен және жоғары суық немесе ыстық дегенді білдіреді.

6) Биологиялық белсенді температура (ББТ) [7]:

$$ББТ = 0,8 ҚЭТТ + 9 \text{ } ^\circ\text{C}, \quad (7)$$

ББТ бойынша бағаланады:

- салқын дискомфорт: 6°C төмен;
- салқын субкомфорт: 6-10°C;
- жылы комфорт: 10–20°C;
- жылы субкомфорт: 20-23°C;
- ыстық дискомфорт: 23°C жоғары.

7) Келтірілген температура ($T_{\text{келт}}$) [8]:

$$T_{\text{келт}} = t - 8,2\sqrt{v}, \quad (8)$$

мұнда $T_{\text{келт}}$ – келтірілген температура, °C;

t – нақты ауа температурасы, °C;

v – жел жылдамдығы, м/с

Келтірілген температурамен бағалағанда келесі критерийлер қолданылады:

- минус 17-0 °C – субкомфорт (әлсіз суық) – адамдардың далада болуына шектеу жоқ;
- минус 17-28 °C – дискомфорт (суық) – әлсіреген немесе жүрек-қантамыр жүйесі бұзылған адамдардың далада болуын біршама шектеу қойылады;
- минус 28-38 °C – орташа дискомфорт (өте суық) – далада қозғалыста немесе жұмыста болған кезде әр 40-50 минут сайын жылы бөлмеде 10-15 минут жылыту қажет;
- минус 38-42 °C – күшті дискомфорт (өте қатты суық) – беттің үсіп қалуы мүмкін. Даладағы жұмыс уақытын 30%-ға қысқарту қажет;
- минус 42 °C төмен – өте күшті дискомфорт (өте қатты суық) – ашық ауада болуды және кез келген жұмысты орындауды толық тоқтату қажет.

ЗЕРТТЕУ НӘТИЖЕЛЕРІ

Климаттың қолайлылығын бағалау үшін 10 метеорологиялық станциялар бойынша ең жылы (шілде) және ең суық (қаңтар) айлардың биоклиматтық индекстері есептелді. Ол үшін алдымен шілде мен қаңтардың көпжылдық орташа (1991-2020 жж.) ауа температурасы (t), ауаның салыстырмалы ылғалдылығы (f) және жел жылдамдығы (V) мәндері анықталды.

Шілде айы бойынша тиімді температура (ТТ), эквивалентті - тиімді температура (ЭТТ), радиациялық эквивалентті - тиімді температура (РЭТТ) және қалыпты эквивалентті - тиімді температура (ҚЭТТ) мәндері есептеліп критерийлері бойынша бағаланды.

Қайтар айы бойынша тиімді температура (ТТ), келтірілген температура ($T_{\text{келт}}$) және Бодман қатаңдық индексі (S) мәндері есептеліп критерийлері бойынша бағаланды.

Кесте 2-де 10 МС бойынша шілде айының метеорологиялық көрсеткіштерінің орташа көпжылдық мәндері берілген. Кестеде метеостанциялар реті солтүстіктен оңтүстік және батыстан шығыс бағытында берілген.

Шілде айының орташа температурасының ең жоғары мәні Қызылқұм шөлінде орналасқан Қызылқұм МС-да (30,0 °С), ал ең төменгі мәні таулы жерде орналасқан Тасарық МС-да (22,2 °С) байқалады.

Шілдеде ауа барлық жерде құрғақ болғандықтан салыстырмалы ылғалдылық мәні 50 %-дан төмен. Жел жылдамдығы Тасты, Түркістан және Рысқұлов МС-да 3,0 м/с жоғары, ал басқа МС-да - төмен.

Кесте 2. Шілде айының метеорологиялық көрсеткіштері (t – ауа температурасы, f – ауаның салыстырмалы ылғалдылығы, v – жел жылдамдығы)

МС	t , °С	f , %	v , м/с
Тасты	27,7	31	3,3
Ащысай	25,7	32	2,4
Түркістан	29,0	33	3,3
Қызылқұм	30,0	30	3,1
Рысқұлов	25,6	38	3,6
Шымкент	26,8	37	2,0
Тасарық	22,2	47	1,5
Қазығұрт	26,9	36	2,6
Шардара	29,2	38	2,8
Жетысай	28,0	43	1,7

Кесте 3-те шілде айының биоклиматтық индекстері берілген. Биоклиматтық индекстермен бағалау нәтижесі бойынша облыс аумағында біршама айырмашылықтар бар.

Шілде айы биоклиматтық 2 индекс (ТТ, ЭТТ) бойынша 4 МС-да «ыстық» болып, ал басқа 8 МС-да «жылы» болып саналады. Ал ҚЭТТ индексі бойынша таулы МС Тасарықтан басқа жердің бәрі «ыстық» болып саналады. РЭЭТ индексі бойынша МС Тасарықтан басқа жердің бәрі «жылы субкомфорт», яғни «ыстыққа» жақын болып саналады.

Сонда жалпы алғанда шілде айы адамдар үшін 4 МС-да ыстық, 5 МС-да ыстыққа жақын, ал 1 МС-да жылы болып бағаланады. Сондықтан Түркістан облысының жазық жерлері адамның тұрмыс-тіршілігі үшін жазда ыстық қолайсыз, ал таулы жерлері – жылы қолайлы болып саналады.

Кесте 3. Шілде айының биоклиматтық индекстері

МС	ТТ		ЭТТ		РЭТТ		ҚЭТТ	
	ТТ	ЖЫЛЫ	ЭТТ	ЖЫЛЫ	РЭТТ	ЖЫЛЫ	ҚЭТТ	ЫСТЫҚ
Тасты	22,8	ЖЫЛЫ	20,2	ЖЫЛЫ	28,8	ЖЫЛЫ субкомфорт	23,2	ЫСТЫҚ
Ащысай	21,4	ЖЫЛЫ	18,8	ЖЫЛЫ	27,6	ЖЫЛЫ субкомфорт	22,0	ЫСТЫҚ
Түркістан	24,0	ЫСТЫҚ	21,7	ЫСТЫҚ	30,0	ЖЫЛЫ субкомфорт	24,3	ЫСТЫҚ
Қызылқұм	24,4	ЫСТЫҚ	22,5	ЫСТЫҚ	30,7	ЖЫЛЫ субкомфорт	25,0	ЫСТЫҚ
Рысқұлов	21,7	ЖЫЛЫ	18,3	ЖЫЛЫ	27,2	ЖЫЛЫ субкомфорт	21,7	ЫСТЫҚ
Шымкент	22,6	ЖЫЛЫ	20,4	ЖЫЛЫ	28,9	ЖЫЛЫ субкомфорт	23,3	ЫСТЫҚ
Тасарық	19,6	ЖЫЛЫ	16,9	ЖЫЛЫ	26,0	ЖЫЛЫ комфорт	20,5	ЖЫЛЫ
Қазығұрт	22,6	ЖЫЛЫ	20,1	ЖЫЛЫ	28,7	ЖЫЛЫ субкомфорт	23,1	ЫСТЫҚ
Шардара	24,4	ЫСТЫҚ	22,4	ЫСТЫҚ	30,6	ЖЫЛЫ субкомфорт	24,9	ЫСТЫҚ

Жетысай	24,0	ЫСТЫ қ	22,1	ЫСТЫ қ	30,4	ЖЫЛЫ субкомфорт	24,7	ЫСТЫ қ
---------	------	-----------	------	-----------	------	--------------------	------	-----------

Кесте 4-де 10 МС бойынша қаңтар айының метеорологиялық көрсеткіштерінің орташа көпжылдық мәндері берілген.

Қаңтар айының орташа температурасының ең жоғары мәні Шу өзенінің төменгі ағысының сол жақ бетінде орналасқан Тасты МС-да (-8,1 °С), ал ең жоғарғы мәні Жетісай МС-да (0,5 °С) байқалды.

Қаңтар айында ауаның салыстырмалы ылғалдылығының орташа мәні 66-83 % аралығында болады. Жел жылдамдығы Тасты және Рысқұлов МС-да 3,0 м/с жоғары, ал басқа 8 МС-да – одан төмен болады.

Айта кету керек, Түркістан облысының жазық жерлерінде қар жамылғысы тұрақсыздықпен ерекшеленеді, кей жылдары қар болмауы да мүмкін.

Кесте 4. Қаңтар айының климаттық көрсеткіштері (t – ауа температурасы, f – ауаның салыстырмалы ылғалдылығы, v – жел жылдамдығы)

МС	t , °С	f , %	v , м/с
Тасты	-8,1	81	3,5
Ащысай	-2,7	66	1,5
Түркістан	-2,8	79	2,1
Қызылқұм	-3,6	82	1,7
Рысқұлов	-1,2	69	3,1
Шымкент	-0,4	74	1,8
Тасарық	-2,4	71	1,1
Қазығұрт	-0,4	76	2,5
Шардара	-0,2	83	2,6
Жетысай	0,5	81	1,9

Кесте 5-те қаңтар айының биоклиматтық индекстері берілген. Тиімді температура (ТТ) бойынша 5 МС-да қаңтар суық, ал 5 МС-да – жылы болып саналады. Бірақ басқа екі индекстер бойынша ($T_{\text{келт}}$, S) қаңтар айы Түркістан облысының солтүстігінде орналасқан Тасты МС-да ғана «суық» немесе «қыс орташа қатаң» болып саналады. Ал қалған 9 МС-да «әлсіз суық» немесе «қыс әлсіз қатаң» болып саналады.

Жалпы алғанда Түркістан облысында қыс маусымы адамның тұрмыс-тіршілігі үшін тек оның солтүстік шетінде ғана қолайсыздау, ал басқа жерлерінде қолайлы болып саналады.

Кесте 5. Шілде айының биоклиматтық индекстері

МС	ТТ		$T_{\text{келт}}$		S	
	ТТ	сипат	$T_{\text{келт}}$	сипат	S	сипат
Тасты	-6,7	суық	-23,4	суық	2,6	қыс орташа қатаң
Ащысай	-1,0	суық	-12,7	әлсіз суық	1,6	қыс әлсіз қатаң
Түркістан	-1,7	суық	-14,7	әлсіз суық	1,7	қыс әлсіз қатаң
Қызылқұм	-2,6	суық	-14,3	әлсіз суық	1,7	қыс әлсіз қатаң
Рысқұлов	0,2	орташа салқын	-15,6	әлсіз суық	1,9	қыс әлсіз қатаң
Шымкент	0,7	орташа салқын	-11,4	әлсіз суық	1,5	қыс әлсіз қатаң
Тасарық	-1,0	суық	-11,0	әлсіз суық	1,4	қыс әлсіз қатаң
Қазығұрт	0,6	орташа салқын	-13,4	әлсіз суық	1,7	қыс әлсіз қатаң
Шардара	0,5	орташа салқын	-13,4	әлсіз суық	1,7	қыс әлсіз қатаң
Жетысай	1,2	орташа салқын	-10,8	әлсіз суық	1,5	қыс әлсіз қатаң

ҚОРЫТЫНДЫ

Түркістан облысының климатының адамдардың тұрмыс-тіршілігіне қолайлылығын бағалау үшін 10 метеорологиялық станциялар бойынша ең жылы (шілде) және ең суық (қаңтар) айлардың биоклиматтық индекстері есептелді. Шілде айы 4 биоклиматтық индекспен, қаңтар айы 3 биоклиматтық индекспен бағаланды. Зерттеу нәтижесінде адамдардың тұрмыс-тіршілігі үшін Түркістан облысының жазық жерлерінің жазда ыстық қолайсыз, ал таулы жерлерінің – жылы қолайлы екені анықталды. Ал қыс маусымы оның солтүстік шетінде қолайсыздау, басқа жерлерінде қолайлы болады. Жалпы алғанда Түркістан облысының климаты адамдардың тұрмыс-тіршілігі, денсаулығы және жұмыс қабілеттілігі үшін жеткілікті түрде қолайлы деп санауға болады.

ҚОЛДАНЫЛҒАН ӘДЕБИЕТТЕР

1. Бейсенова Ә.С., Қирабаев Ә.С. Қазақстанның географиялық атласы.- Алматы: "Атамұра", 2013. - 104 С.
2. Головина Е.Г., Русанов В.И. Некоторые вопросы биометеорологии. -СПб.: 1993. - 4-9 с.
3. Бокша В.Г. Справочник по климатотерапии. -Киев, Здоровья, 1980. - 118-119 с.
4. Колокотрони К.О., Калмыкова И.Н. Оценка биоклиматических условий на территории Приволжского федерального округа с использованием ГИС технологии. -М.: Издательство Московского Университета, 2003. - 5-26 с.
5. Айзенштат Б.А. Тепловой баланс и микроклимат основных ландшафтов Средней Азии и некоторые вопросы биоклиматологии. Автореф. дис. д-ра геогр. наук. -М., 1969. -134-135 с.
6. Исаева М.В., Переведенцев Ю.П. Особенности биоклиматических условий Приволжского федерального округа. -Казанский государственный университет, 2004. - 4-24 с.
7. Нысанбаева А.С., Әбдіразақ А.К. Тараз қаласының биоклиматтық жағдайларын бағалау. -Вестник КазНУ Серия Географическая №1 (40) Алматы: Қазақ Университеті, 2015. - 36-44 с.
8. Хайруллин К.Ш., Карпенко В.Н. Биоклиматическое региональное районирование СССР за холодный сезон. // Прикладная климатология. -Л.: Гидрометеоздат, 1997. - 129-132 с.

ОЦЕНКА БИОКЛИМАТИЧЕСКИХ УСЛОВИЙ ТУРКЕСТАНСКОЙ ОБЛАСТИ

Аннотация: В статье оценивается пригодность климата Туркестанского края для жизни людей. В результате исследования установлено, что на равнинах Туркестанской области летом не жарко, а в горных районах тепло. А зимний сезон будет неблагоприятным в его северной части и благоприятным в других местах. В целом климат Туркестанской области можно считать вполне пригодным для жизни, здоровья и трудоспособности людей.

Ключевые слова: температура воздуха, влажность воздуха, скорость ветра, биоклиматические индексы.

ASSESSMENT OF BIOCLIMATIC CONDITIONS OF THE TURKESTAN REGION

Annotation: The article assesses the suitability of the climate of the Turkestan region for human life. As a result of the research, it was found that summer is not hot on the plains of the Turkestan region, but warm in the mountainous regions. And the winter season will be unfavorable in its northern part and favorable in other places. In general, the climate of the Turkestan region can be considered quite suitable for life, health and working capacity of people.

Key words: air temperature, air humidity, wind speed, bioclimatic indicators.

АҚПАРАТТЫҚ ҚАУІПСІЗДІК ТӘУЕКЕЛДІГІН БАҒАЛАУДЫҢ ӘДІСТЕРІ МЕН ПРОГРАММАЛАРЫН ТАЛДАУ

Оңталапұлы С.¹, Тасболатұлы Н.¹, Омаркулова Г.Ш.²

¹Астана халықаралық университеті, Астана, Қазақстан

²Қазақ технология және бизнес университеті, Астана, Қазақстан

Аңдатпа. Ақпараттық қауіпсіздікті ұйымдастыру кез келген мекеменің стратегиялық дамуының маңызды факторын құрайтындықтан, ақпараттық қауіпсіздік тәуекелдігін басқару әдістері арқылы тәуекелдік параметрлерін анықтап, оған бағалау жүргізіп, тәуекелдікті басқару стратегиясын негіздеуге бағытталған. Сондықтан ақпараттық тәуекелдікті бағалау мен қауіптерін талдап, оның алдын алу процесін орындау өзекті мәселелер ретін құрайды. Мақалада CORAS, CRAMM, OCTAVE, STRIDE, DREAD, MONARC, MAGERIT, FAIR сияқты ақпараттық қауіпсіздік тәуекелдіктерін талдау әдістемелері қарастырылды. Талдау ақпараттық ресурстардың құндылығын, төнетін қауіп мен осалдылығын бағалау және оған қарсы жүргізілетін әрекеттер ретін таңдау тиімділігін анықтаудан құралады. Сонымен қатар RiskWatch, Risk management tools, Qualys, SAP Risk Management, Palisade @RISK программалық құралдарын келтірілген критерийлерге сәйкес салыстырмалы талдау жүргізілді, олардың ерекшеліктері сипатталды. Жүргізілген салыстырмалы талдау компанияларға тәуекелдікті талдау әдістерін таңдауды жеңілдетуге мүмкіндік береді.

Кілттік сөздер: ақпараттық тәуекелдік, ақпараттық қауіпсіздік, бағалау әдістері, сандық бағалау, сапалық бағалау, CORAS, CRAMM, OCTAVE, STRIDE, DREAD, MONARC, MAGERIT, FAIR

КІРІСПЕ

Қазіргі кезде интернет пен технологиялардың қарқынды дамуына байланысты, экономика өркендеуіне әсер ететін ақпараттық қауіпсіздікті бағалау өте маңызды және күрделі қадамдардың бірі болып табылады. Мекемелердің жұмысында ақпараттық жүйелер мен технологиялардың рөлінің артуына байланысты тәуекелдікті қадағалау, ақпараттық жүйелердің тәуекелдіктерін басқару және оны бағалау процедураларын қолдану жылдан жылға үлкен маңызға ие. Ақпараттық қауіпсіздікті ұйымдастыру кез келген мекеменің стратегиялық дамуының маңызды факторын құрайды. Сондықтан, бүгінгі күнде ақпараттық тәуекелді бағалау, аудиттің міндеттерін жүргізу бүкіл әлем үшін ғылыми мәселелердің негізін қалайды.

Ақпараттық қауіпсіздік тәуекелдігін басқару әдістері тәуекелдік параметрлерін анықтап, оған бағалау жүргізіп, тәуекелдікті басқару стратегиясын негіздеуге бағытталған. Тәуекелдікті талдаудың базалық және толық түрлері белгілі. Базалық талдау тәсілі жобаға кішігірім талаптар қойылып, тәуекелдікті

сапалық бағалау әдісін пайдалануға мүмкін болғанда қолданылады. Ал қауіпсіздікке талаптар көтеріңкі болған жағдайда, тәуекелдікті бағалаудың сандық бағалау әдісін пайдаланған абзал. Бұл талдау ақпараттық ресурстардың құндылығын, төнетін қауіп мен осалдылығын бағалау және оған қарсы жүргізілетін әрекеттер ретін таңдау тиімділігін анықтаудан құралады.

Мақалада алдымен тәуекелді бағалау, классификациялау ұғымына көңіл бөлініп, одан кейін ақпараттық қауіпсіздік тарапынан тәуекелдіктерді бағалау әдістері мен дайын шешімдердің салыстырмалы талдауы көрсетіледі. Тәуекелдікті бағалауды олардың қасиеттеріне байланысты бірнеше классификацияға бөлуге болады. Олар келесідей:

- әдістемесіне байланысты: ISO 27001, OCTAVE, CORAS, CRAMM, DREAD, STRIDE, MAGERIT, FAIR және т.б. сияқты көптеген әдістемелер бар;
- тәуекелдік категорияларына байланысты: техникалық осалдықтар, программалық осалдықтар, қолданушы жіберген қателіктер, деректердің толыққанды қорғалмауы, программалық кодтан жіберілген қателіктер, ақпараттық жүйелермен өзара алмасу болғандағы проблемалар және т.б.;
- тәуекелдік түрлеріне байланысты: тәуекелдікті бағалау әр түрлі тәуекел түрлеріне байланысты жүргізіледі, мысалы, ақпараттық қауіпсіздік, қаржылық тәуекелдік, операциялық тәуекелдік, өндірістік тәуекелдік, инвестициялық тәуекелдік, транспорттық тәуекелдік, экологиялық тәуекелдік және т.б.;
- қолданушылардың білімі мен тәжірибесі деңгейіне байланысты: қызметкерлердің білмей жасалған әрекеттері әсерінен, біреуге қолжетімділікті беру, қызметкерлердің немесе қолданушылардың қаскүнемдермен шабуыл жасауға арналған құралдарын ашқаннан және жүктегеннен пайда болатын тәуекелдіктер, мысалы, спамдар, сілтемелер, фишинг, эксплоит, трояндарды жіберу және т.б.;
- бағалау объектісіне байланысты: ақпараттық жүйелерді, веб-қосымшаларды, мобильді қосымшаларды, олардың компоненттерін, деректер базасын, бұлтты қызметтерді, қосымша процесстерді тәуекелдік тарапынан бағалау;
- бағалау типіне байланысты: тәуекелдікті бағалау сандық немесе сапалық әдіс көмегімен жүргізіледі. Сапалық әдіс төмен, орта және жоғарғы деңгейлер арқылы қауіптің пайда болуы мен ақпараттық жүйелерге әсерін сипаттайды. Сандық әдіс ақпараттық жүйелерге әсер ететін қауіптер мен олардың әсер ету ықтималдығын сандық есептеулер жүргізу арқылы анықтайды.
- нақтылық деңгейіне байланысты: тәуекелдікті бағалау объективті немесе субъективті болуы мүмкін. Объективті бағалау нақты деректер мен оқиғаға

негізделсе, субъективті бағалау сарапшылардың пікіріне және тәжірибесіне сүйенеді;

- детализациялау деңгейіне байланысты: тәуекелдікті бағалау жалпы немесе егжей-тегжейлі жүргізілуі мүмкін. Жалпы бағалауда мекеме үшін жалпы қасеттер анықталып, жалпы тәуекелдік пен қауіп бағаланады, ал егжей-тегжейлі бағалауда нақты жағдай мен сценарийге негізделген қауіп пен осалдықты айқындау жүргізіледі;
- нәтижелер түріне байланысты: тәуекелдікті бағалау нәтижесі әр түрлі форматтарда ұсынылуы мүмкін, мысалы, тәуекелдік матрицасы, тәуекелдік тізімі, тәуекелдік бойынша есептер түрінде және т.б.;
- деректерді жинақтау әдістеріне байланысты: тәуекелдікті бағалау деректерді жинақтаудың әр түрлі әдістері көмегімен жүргізілуі мүмкін, мысалы, сауалнама, сұхбат, құжаттарды талдау және т.б.;
- деректердің сапасына байланысты: тәуекелдікті бағалау процесінің тиімді және дұрыс жүргізілуі деректердің сапасына тікелей байланысты болады.
- қоршаған орта факторлары деңгейіне байланысты: заңнамалық талаптар, экономикалық факторлар, әлеуметтік жағдайлар және т.б.;
- белгісіздік жағдайына байланысты: тәуекелдікті бағалау кезінде пайда болатын белгісіздік жағдайларын есепке алу арқылы жүргізіледі.
- мекеменің жеке ерекшеліктеріне байланысты: тәуекелдікті бағалау мекеменің бизнес-моделіне, мақсаты мен міндеттеріне, корпоративті мәдениетіне және т.б. ерекшеліктеріне байланысты жүргізіледі.
- тәуекелдіктің пайда болу ықтималдығына байланысты: статистикалық деректерге, сарапшы бағалауына, бұрынғы тәжірибеге негізделіп, тәуекелдікті бағалау жүргізіледі.
- экономикалық құндылығына байланысты: тәуекелдікті қабылдаудан болатын кірісі, зарар құны және т.б. қасиеттері есепке алынады.

Осы классификацияға байланысты маңызды ерекшеліктер мен қасиеттерге баса көңіл аударып, мекемеде болатын тәуекелге бағалау процесін жүргізу қажет.

Зерттеу материалдары мен әдістері бөлімінде ақпараттық қауіпсіздік саласында тәуекелдіктерді бағалау әдістері мен оны анықтау мен бақылауға арналған дайын шешімдерге салыстырмалы талдаулар жүргізілді. Нәтижелер мен талдаулар бөлімінде тәуекелдікті талдауға арналған программалық қамтаманы салыстыру критерийлері мен олардың қасиеттері кесте түрінде көрсетілді.

ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӘДІСТЕРІ

Ақпараттың ауқымды көлемі бар заманда ақпараттық қауіпсіздіктің алатын орны ерекше. Сондықтан ақпараттық қауіпсіздік саласындағы тәуекелдіктерді бағалау ерекше маңызға ие. Зерттеу жұмысы барысында нақты қажеттіліктерге, компания мүмкіндіктері мен тәуекелдікті талдау тәсілдерін таңдау процедурасына, заманауи бизнеске бағытталған шешім қабылдаудың тиімді жүйесіне басты көңіл бөлінді.

Кесте 1 Ақпараттық қауіпсіздік тәуекелдіктерін бағалау әдістерін салыстырмалы талдау

№	Әдістердің атауы	Салыстыру критерийлері						Пайдаланылатын стандарттар
		Ресурс	Қауіп	Осалдық	Қауіпсіздік талаптары мен шаралары	Сапалық бағалау	Сандық бағалау	
	CORAS	1	1	1	0	1	1	CORAS, ISO 27005
	CRAMM	1	1	1	0	1	1	CRAMM, ISO 27002
	OCTAVE	1	1	1	1	1	0	OCTAVE
	STRIDE	1	1	1	1	1	1	STRIDE
	DREAD	1	1	1	1	1	0	Microsoft Security Development Lifecycle
	MONARC	1	1	1	1	1	0	ISO/IEC 27001, ISO/IEC 27005, PCI-DSS стандарт
	MAGERIT	1	1	1	1	1	1	ISO/IEC 27002
	FAIR	0	1	1	0	0	1	ISO/IEC 27002

ТАЛДАУ НӘТИЖЕСІ

CORAS. CORAS әдісі қауіптер мен тәуекелдер диаграммалары көмегімен осалдық, қауіптер мен тәуекелдікті құрылымды анықтауға және жүйеге келтірілетін залалдар мен таралу процесстерін талдауға, оны визуализациялауға мүмкіндік береді. Бірақ мұнда жүйені компрометациялайтын қауіптерді анықтау процесі жоқ. Бұл әдіс өте қарапайым және арнайы білімді қажет етпейді. Әдістеменің кемшілігіне тәуекелдікті бағалау жиілігінің қарастырылмауы жатады. Сапалық тәсіл сарапшылар тәжірибесі негізінде және нақты салада білімдерді бағалау арқылы жүргізіледі. Сандық тәсіл математикалық модельге негізделген, нақты жүйеде қауіптің пайда болуы мен оның әсерін болдырмау ықтималдылығын анықтайды. STRIDE әдісі арқылы анықталған қауіптер CORAS арқылы талдау жүргізу кезінде кіріс деректері ретінде пайдаланылып, идентификациялануы күрделі қауіптер мен осалдықтарды анықтауға мүмкіндік береді. URL: <https://coras.sourceforge.net/>.

CRAMM (CCTA Risk Analysis and Management Method). CRAMM процесі келесідей кезеңдерді қосады: активтерді идентификациялау, осалдықты идентификациялау, тәуекелдікті бағалау, бақылау құралдарын идентификациялау, бақылау құралдарын ендіру, тәуекелдікті басқару. Бұл әдісте тәуекелді талдаудың сандық және сапалық әдістері пайдаланылады. Сапалық әдіс бизнес-процесстер үшін қауіптердің пайда болу ықтималдығын, жүйедегі осалдықты анықтауды қарастырады. Сандық әдіс жүйеге болжамды қауіптердің пайда болу ықтималдығы мен әсер етуін нақтырақ бағалауға бағытталған. URL: https://www.enisa.europa.eu/topics/risk-management/current-risk/risk-management-inventory/rm-ra-methods/m_cramm.html.

OCTAVE (Operationally Critical Threat, Asset, and Vulnerability Evaluation). OCTAVE әдісі маңызды критикалық қауіптерді, активтерді және осалдықты бағалауға арналған әдіс, ол тәуекелдікті бағалаудың күрделі тәсілін ұсынады және ірі иерархиялық мекемелерде ақпараттық қауіпсіздік тәуекелдігін стратегиялық бағалау активтеріне негізделеді. Бұл әдіс мекеменің тәуекелдігінің сандық бағалау тәсілін жүргізбейді, әр түрлі жұмыстармен айналысатын мекемелерге сәйкес келеді. Сапалық әдісте қауіпсіздіктің бұзылуына септігін тигізетін ықтимал қауіптер мен осалдықтарды анықтау жүргізіледі. URL: <https://resources.sei.cmu.edu/library/asset-view.cfm?assetid=51546>

STRIDE. STRIDE әдісінің аббревиатуралары келесі сөздерден құралған: spoofing, tampering, repudiation, information disclosure, denial of service, elevation of privilege. Spoofing шабуылы авторизацияланбаған қолданушының авторизацияланған қолданушы ретінде өзін ұсынуы немесе зиянды программаның өзін легитимді программа ретінде көрсетуі. Tampering – қандай да бір мақсатқа жету үшін программалық жүйедегі деректерді қаскүнемнің өзгертуіне мүмкіндік беретін әдіс. Repudiation – қаскүнемге программалық жүйемен ешқандай зиянды

әрекеттер жүргізілмегендігін көрсетуге мүмкіндік береді, себебі жүйенің оған қарсы дәлелі жоқ. Information disclosure қауіп типінде қаскүнем авторизацияланбаған қолданушыларға жүйеге кіру, кредиттік / дебеттік карта нөмірі және т.б. қорғалған ақпаратты ашуға септігін тигізеді. Denial of service қауіп арқылы қаскүнем заңды қолданушыларға программалық жүйенің жалпы функцияларын пайдалануға кедергі келтіреді. Elevation of privilege қауіп барысында қаскүнем жүйеге қосымша құқық пен привилегия алады. Сондықтан бұл әдіс жүйенің әрбір компонентінің киберқауіптерін анықтауға арналған жүйелік талдау әдісі болып табылады. Ол аутентификация, авторизация, жүйенің бүтіндігі, құпиялылығы, қолжетімділігі сияқты қауіпсіздік қасиеттеріне байланысты киберқауіптерді талдайды. Бұл әдіс қауіптің алты категориясын талдауға негізделген. Сапалық әдіс нақты қауіппен байланысты тәуекелдіктер мен жүйенің осалдығын анықтауға байланысты. Сандық әдісте әрбір қауіптің пайда болуы мен оның жүйеге әсерінің ықтималдығы бағаланады. URL: <https://threat-modeling.com/stride-threat-modeling/>.

DREAD (Damage, Reproducibility, Exploitability, Affected users, and Discoverability). Бұл әдіс тәуекелдіктің нақты сипаттамалары бойынша бағалау процесін жүргізуге бағытталған. Сапалық бағалауда критерийлерді 0 мен 10 аралығындағы шкаламен, бес қасиетін өзара көбейту арқылы жүргізеді. 1-10 аралығы инфрақұрылым мен деректер үшін төменгі тәуекелдік, 11-24 аралығы орта деңгей, мұнда критикалық тәуекелдікті жойғаннан кейінгі қалыпты тәуекелдік, 25-39 аралығы жоғарғы осалдық, 40-50 аралығы критикалық осалдық болып есептеледі. URL: <https://eccouncil.org/cybersecurity-exchange/threat-intelligence/dread-threat-modeling-intro/>.

MONARC (Méthode Optimisée d'analyse des risques CASES – 'Method for an Optimised Analysis of Risks by CASES'). Бұл әдіс төрт кезеңде жүзеге асырылады, оның әрқайсысы ISO/IEC 27005:2011 халықаралық стандартының ақпараттық қауіпсіздікке қатысты тәуекелдікті басқару бойынша нұсқауларына сәйкес келеді. Сапалық бағалауда ақпараттық жүйеге шабуыл жасау үшін қаскүнемдер пайдаланатын осалдықтарды идентификациялау негізінде тәуекелдікті бағалау процесі жүргізіледі. URL: <https://www.monarc.lu>.

MAGERIT (Methodology for Analysis and Management of Information Technology Risks). MAGERIT әдістемесі келесі кезеңдерден тұрады: тәуекелдікті идентификациялау, тәуекелдікті бағалау, тәуекелдікті өңдеу, тәуекелдік туралы хабарлау, тәуекелдікті мониторинг жасау. Бұл әдіс мекемеде сәйкес қауіпсіздік шаралары мен сертификаттау және тексеруге көмектесу үшін пайдаланылады. Ақпараттар, қызметтер, программалық қамтамалар, құралдар сияқты активтерді идентификациялап, 0-10 аралығындағы шкала бойынша бағалау критерийлерін жүргізеді. URL: PAe - MAGERIT v.3: Metodología de análisis and risk management information systems (administracionelectronica.gob.es).

FAIR (Factor Analysis of information risk). FAIR әдістемесі келесі кезеңдерден тұрады: талдау көлемі, тәуекелдік сценарийін анықтау, тәуекелдік факторларын анықтау және талдау, тәуекелдікті есептеу, тәуекелдікті бағалау, тәуекелдікпен күрес, талдау және мониторинг. Бұл әдіс ақпараттық тәуекелдікті талдау, сандық бағалау мен өлшемдер жүргізуге бағытталған, сондай-ақ ақпараттық тәуекелдікті факторлық талдау моделінің базалық формасы төрт кезең арқылы орындалады. URL: <https://www.fairinstitute.org/what-is-fair>.

Осы қарастырылған әдістер тәуекелдікті талдау мен бағалау процесінің кеңейтілген мүмкіндіктерін ұсынады. Сонымен қатар келесі бөлімде тәуекелдікті талдауға арналған программалық құралдарда сандық және сапалық бағалау тәсілдері қарастырылғандығы зерттеліп, көрсетілді.

НӘТИЖЕЛЕР МЕН ТАЛДАУЛАР

Ақпараттық қауіпсіздік жай қолданушыларға ғана емес, сонымен қатар мекемелерге де өте маңызды болғандықтан, қауіптерді анықтау мен тәуекелдіктерді бағалауды жан-жақты талдау жүргізген абзал. Мекемелердегі тәуекелдікті талдау процесін қарастырып, өндірістегі тәуекелдік ықтималдығы формуласын нақты осалдық пен тәуекелдік нәтижесі осалдықтың пайда болу ықтималдығы мен болжамды зарарына көбейткеніне тең болады деп келтірсе болады [1].

$$\text{Тәуекелдік} = \text{Ықтималдық} * \text{Болжамды зарар} \quad (1)$$

Бұл формулада ықтималдық пен болжамды зарар 10 балдық шкала арқылы есептеледі, мұндағы 1 мәні қауіптің пайда болу ықтималдығының төменгі деңгейін, ал 10 – жоғарғы деңгейін көрсетеді. Осы формулаға сәйкес, егер ықтималдықты 3-ке тең деп, ал болжамды зарарды 10 деп алса, онда тәуекелдік 30% құрайды. DREAD тәуекелдікті бағалау моделі көмегімен тәуекелдікті бағалау үшін келесі формуланы пайдалануға болады [1].

$$\text{DREAD_Risk_Value} = (\text{DAMAGE} + \text{REPRODUCIBILITY} + \text{EXPLOITABILITY} + \text{AFFECTED USERS} + \text{DISCOVERABILITY}) / 5 \quad (2)$$

Зарар, тәуекелдікті іске қосу, пайдалану мүмкіндіктері, зиян келтірілген қолданушылар, зиянды әсерлерді анықтау сияқты параметрлерді қосып, оларды 5-ке бөлу арқылы Dread тәуекелдік өлшемі алынады.

Ақпараттық қауіпсіздік тәуекелдіктерін бағалау міндеттерін шешу үшін Кесте 2 көрсетілген программалық қамтамалар зерттеліп, оларды салыстырып, олардың салыстыру критерийлері анықталды.

Кесте 2 Ақпараттық қауіпсіздік тәуекелдігін талдауға арналған программалық қамтаманы салыстыру

№	Салыстыру критерийлері	Программалық қамтама				Palisade @RISK
		RiskWatch	Risk management tools	Qualys	SAP Risk Management	
	Бағасы		Тегін, 100\$-10000\$ дейін	Жылына 995\$-2495\$ аралығы		Жылына 2,125\$, 2.765\$
	Стандарттарды қолдауы	ISO 17799	IEC 31010	ISO 27001	ISO 31000	ISO 31000
	Тәуекелдік категорияларын пайдалану	+	+	+	+	+
	Тәуекелдікті төмендету	+	+	+	+	+
	Осалдықтар	+	+	+	+	+
	Қауіптер	+	+	+	+	+
	Сапалық бағалау	+	+	+	+	-
	Сандық бағалау	+	+	-	+	+

Ақпараттық жүйелерге әсер ететін барлық қауіптер, осалдықтар мен тәуекелдіктерді талдауды жан-жақты жүргізіп, олардың халықаралық стандарттар мен нормаларға сәйкестігін ғана емес, сонымен қатар қолданушылар енгізген деректер мен жүйедегі өзгерістерді бақылап, осылардың негізінде ақпараттық қауіпсіздік үшін ағымдағы қауіп-қатер мен осалдықтың моделін құруға болады. Алынған модель негізінде әрбір ресурс үшін ақпараттық қауіпсіздік қаупін жүзеге асыру ықтималдығын талдау жасап, сәйкес тәуекелдікті есептеу шараларын жүргізуге болады.

ҚОРЫТЫНДЫ

Ақпараттық қауіпсіздік саласындағы халықаралық стандарттар мен әлемдік практика ақпараттық жүйенің қауіпсіздігінің тиімдігін басқару үшін тәуекелдікті басқару мен талдау жүйелерін енгізуді талап етеді. Ақпараттық тәуекелдікті басқару мен талдау ақпараттық жүйені тиімді қорғаныс процедураларын қамтамасыз етуге арналған маңызды фактор болып табылады.

Зерттеу жұмысында ақпараттық қауіпсіздік тәуекелдіктерін бағалау әдістерін салыстырмалы талдау мен программалық қамтаманы салыстыру процесстері жүргізілді. Жасалған салыстырмалы талдау мекемелерге тәуекелдікті талдау әдістерін таңдау процедурасын жеңілдетуге мүмкіндік береді.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Md Tarique Jamal Ansari, Dharendra Pandey, Mamdouh Alenezi STORE: Security Threat Oriented Requirements Engineering Methodology // Journal of King Saud University – Computer and Information Sciences. – 2022. – p. 191–203

2. Е.К. Баранова, А.А. Мурзакова, Е.А. Мурзакова Сравнительный анализ программного обеспечения для анализа рисков информационной безопасности в соответствии с ГОСТ Р ИСО/МЭК 27005\$10 // Информационные технологии и вычислительные системы. – 2/2019

3. Қ.И. Сағындық, Ж.М. Алимжанова, К. Sagyndyk Аудит информационной безопасности методами оценочного динамического моделирования // PERSPECTIVE OF SCIENCE AND PRACTICE Abstracts of XIII International Scientific and Practical Conference. – 2021. – 305-315 с.

4. Compendium of risk management frameworks with potential interoperability // Supplement to the Interoperable EU Risk Management Framework Report. – 2022

5. D. Ki-Aries, Sh. Faily, H. Dogana, Ch. Williams Assessing system of systems information security risk with OASoSIS // Computers & Security. – 2022

6. Н. А. Староверова, З. Фадхкал Анализ существующих методов оценки рисков корпоративных информационных систем. – 2013. – 282-287 с.