

**Прогнозування площі поширення морського льоду засобами
штучного інтелекту**

EarthSaverAI

Зміст

I. Вступ.....	3
II. Огляд джерел.....	4
III. Методологія.....	6
IV. Результати	8
V. Використані джерела.....	28

I. Вступ

Площа морського льоду в Арктиці та Антарктиці є одним із семи основних кліматичних показників, визначених Всесвітньою метеорологічною організацією (ВМО) [1]. Цей показник має значний вплив на екосистеми арктичного та антарктичного регіонів, а також на інші регіони земної кулі, і відіграє значну роль у зміні клімату.

Визначення основних тенденцій та закономірностей змін площі морського льоду є надзвичайно актуальним у контексті розуміння потенційних ризиків не лише для полярних регіонів, але й для всієї біосфери. Вивчення часових рядів змін площі морського льоду надає надзвичайно цінну інформацію для вибору методів та моделей прогнозування майбутніх показників.

Площа арктичного та антарктичного льоду демонструвала стабільні тенденції протягом десятиліть, але сьгоднішні спостереження вказують на аномально низькі рівні [2].

Політикам, планувальникам, інвесторам та вразливим громадам потрібна інформація про майбутній клімат, щоб вони могли підготуватися до очікуваних тенденцій та змін [3].

Дане дослідження присвячене вивченню зміни клімату з використанням методів штучного інтелекту (ШІ) та машинного навчання (ML).

Головною метою дослідження є розробка рішення на основі штучного інтелекту, яке підтримує екологічну стійкість та вирішує проблеми зміни клімату.

Щоб уникнути будь-яких ризиків, необхідно забезпечити відповідальне проведення досліджень. Зокрема, використовувати лише надійні набори даних, надані міжнародними організаціями (NASA, ВМО). Для точності прогнозу доцільно використовувати різні підходи, включаючи статистичний аналіз даних, а також оцінку ефективності моделей машинного навчання за допомогою відомих метрик. Це дозволить уникнути проблем надмірного або недостатнього налаштування та допоможе зменшити потенційні ризики при прогнозуванні аномальних значень.

Щоб уникнути юридичних та етичних ризиків, планується використовувати методології з відкритим кодом та впроваджувати політику управління даними з урахуванням етичних та правових стандартів.

Тема дослідження визначається Цілями сталого розвитку (ЦСР), визначеними Організацією Об'єднаних Націй (ООН) та прийнятими всіма державами-членами ООН у 2015 році. З огляду на ЦСР 13, зміна клімату є реальною та незаперечною загрозою для всієї нашої цивілізації [5].

Основною Ціллю сталого розвитку (ЦСР) для представленого дослідження є Ціль 13 . Дії щодо зміни клімату.

Запропонована інформаційна система може допомогти надати критично важливі дані для розуміння та пом'якшення наслідків зміни клімату на полярні регіони.

Крім того, морський лід відіграє життєво важливу роль в морських екосистемах Арктики та Антарктики, забезпечуючи середовище існування для таких видів, як білі ведмеді, тюлені та криль. Також наземні екосистеми в полярних регіонах, такі як тундра та вічна мерзлота, тісно пов'язані з умовами морського льоду. Таким чином, тема дослідження безпосередньо пов'язана з ЦСР-14 (Життя під водою) та ЦСР-15 (Життя на суші).

II. Огляд джерел

Було проаналізовано роботи, в яких досліджувався вплив температури поверхні на зміну клімату, підходи до прогнозування часових рядів температури [6, 7], вплив такого прогнозування в контексті розвитку сталих міст та громад [8], а також специфіка розробки прогнозних інформаційних систем [4, 9].

Це дослідження зосереджено на вивченні часових рядів поширення морського льоду. Хоча дослідження мають деякі спільні закономірності, такі як сезонність, специфіка полярних регіонів вимагає комплексного аналізу, який враховує кліматичні характеристики досліджуваних регіонів.

Зміни льодового покриву Арктики та Антарктиди впливають на рівень моря [2], кількість опадів [10-13], висоту прибережних хвиль [14] та багато інших

показників, перетворюючи цілі регіони на зони, вразливі до зміни клімату [15]. Морський лід також має значний вплив на флору та фауну [16-18].

У статті [19] встановлено кореляцію між історичними тенденціями щодо площі морського льоду в різних морях Північного полярного кола шляхом аналізу впливу на них змін температури в Північному полярному колі та середньорічної концентрації глобального CO². Важливим аспектом дослідження Арктичного регіону є аналіз озеленення території, який демонструє тенденції зростання [20].

Також, під час вивчення кліматичних даних, велика увага приділяється аналізу часових рядів, зокрема вивченню сезонних закономірностей.

У роботі [21] розглядаються сезонні тенденції початку ХХ століття та проводиться детальний статистичний аналіз даних. У дослідженні [22] пропонується модель, яка використовує теорію розкладання часових рядів для прогнозування температури в китайських містах.

У низці досліджень тест Дікі-Фуллера використовується для перевірки стаціонарності кліматичних даних. Зокрема, під час вивчення кліматичних тенденцій для басейну тропічних річок Індії [23], змін нестационарних екстремальних опадів через зміну клімату у Східній Малайзії [24] та захворюваності на лихоманку денге через зміну клімату в Сінгапурі [25].

У статті [26] розкрито методи пост-обробки, засновані на машинному навчанні з учителем, для покращення якості прогнозів концентрації морського льоду за допомогою системи прогнозування TOPAZ4. Для короткострокового прогнозування використовується підхід глибокого навчання.

У роботі [27] описано можливості та проблеми розвитку дистанційного зондування арктичного морського льоду за допомогою штучного інтелекту та глибокого навчання.

Існує кілька підходів до прогнозування часових рядів, включаючи авторегресори [28-30], рекурентні [31-34] та згорткові [35, 36] нейронні мережі. Більшість досліджень використовують підхід довготривалої короткочасної пам'яті. Також деякі статті досліджують Bi-LSTM [37, 38], хоча його

використання є суперечливим і дискусії тривають. Таким чином, у цьому дослідженні буде доречно використовувати такі методи прогнозування: SARIMA, LSTM та Bi-LSTM.

III. Методологія

Прогнозування на основі штучного інтелекту спирається на надійні набори даних, які фіксують динаміку даних часових рядів з плином часу. Моделі штучного інтелекту, які можна використовувати для прогнозування площі морського льоду, варіюються від традиційних алгоритмів машинного навчання до передових методів глибокого навчання. Необхідно оцінювати продуктивність у різних часових горизонтах та досліджувати стійкість моделі в екстремальних умовах, таких як рекордно низькі льодовикові роки. Також важливо сприяти довірі, прозорості та ефективній інтеграції технологій штучного інтелекту в глобальні кліматичні ініціативи. На рисунку 1 представлена методологія дослідження.

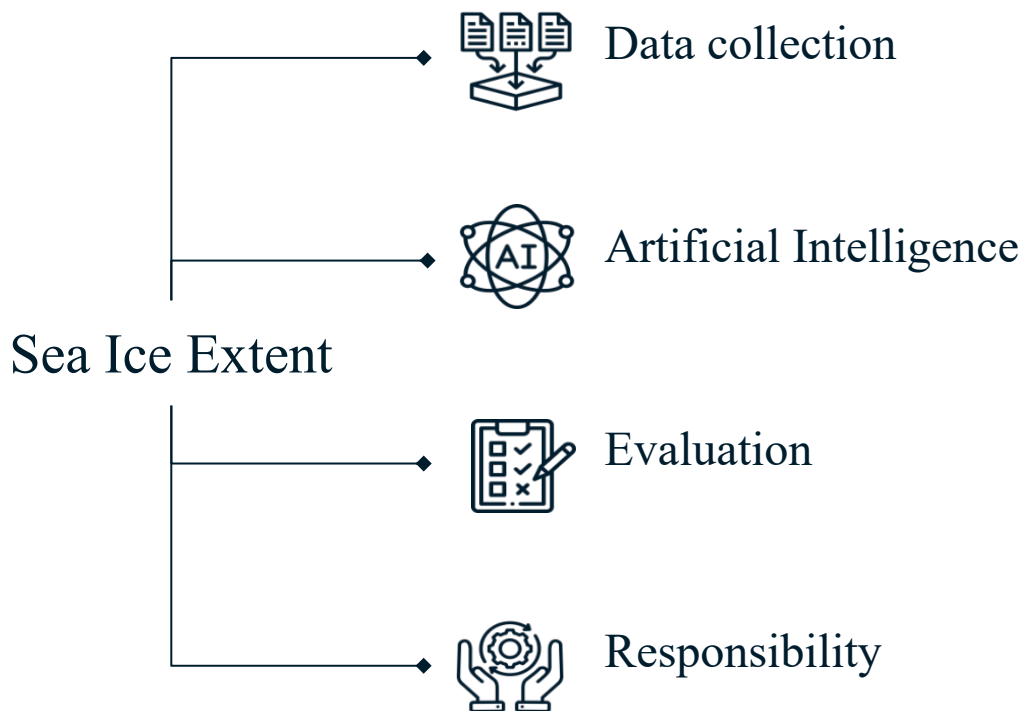


Рисунок 1. Методологія дослідження

Набір даних

У цій роботі було використано набір даних «Daily Sea Ice Extent Data», доступний на Kaggle [39]. Він наданий Національним центром даних про сніг та

лід (NSIDC) [40] та містить щоденні дані про площу морського льоду як для Арктики, так і для Антарктики з 1978 року по теперішній час. Набір даних включає 7 змінних:

- Рік;
- Місяць;
- День;
- Протяжність (одиниця вимірювання 10^6 км²);
- Відсутнє (одиниця площі 10^6 км²);
- Джерело: веб-сайт з вихідними даними [40];
- Півкуля.

Поточний набір даних обмежений даними з 26 жовтня 1978 року по 31 травня 2019 року. Але інформація наступних років представлена Національним центром даних про сніг та лід.

Методи

Задля аналізу даних часових рядів проводиться низка досліджень. Для визначення загальних тенденцій доцільно агрегувати дані, обчислюючи середньомісячну температуру для кожного місяця кожного року. Потім будуються графіки та виконується лінійна апроксимація. Далі обчислюється кут між отриманою лінією та віссю часу. Отриманий результат вказує на загальні тенденції щодо площі морського льоду . Негативний результат вказує на тенденцію до її зменшення, позитивний результат – на збільшення, а результат, близький до нуля, – на відсутність суттєвих змін. Також, для більш повного розуміння змін та вибору методів прогнозування [41], необхідно розкласти часовий ряд на три основні компоненти: Тренд, Сезонність та Залишки.

Оскільки статистичний аналіз не дозволяє отримати цілісного розуміння процесів через свої обмеження, зокрема нездатність виявити приховані закономірності, було вирішено провести аналіз даних за допомогою методів машинного навчання в умовах навчання без учителя [42, 43], зокрема кластеризації K-середніх, просторової кластеризації додатків з шумом на основі щільності (DBSCAN) та ієрархічної кластеризації. Використання цих методів

надасть більше інформації про тенденції щодо поширення морського льоду та існуючі аномалії в даних [44].

Існує кілька підходів до прогнозування часових рядів. Однак, враховуючи тему дослідження та необхідність довгострокового прогнозування, ми зосередимося на сезонній авторегресії та алгоритмах глибокого навчання: SARIMA, LSTM, Bi-LSTM та ансамблевих моделях на їх основі [45-49].

Для оцінки ефективності прогностичної моделі в задачі регресії вимірюються різні аспекти продуктивності. Найпоширеніші метрики включають [50, 51]:

- R-квадрат (R^2);
- Середня абсолютна похибка (MAE);
- Середньоквадратична похибка (MSE);
- Зважена середньоквадратична похибка (RMSE).

IV. Результати

Для оцінки коливань площі морського льоду дані були агреговані шляхом розрахунку середньомісячних значень. Результати візуалізації для кожного місяця з 1979 по 2018 рік представлені на рис. 2, 3.

У таблиці 1 наведено максимальні, мінімальні та середні значення площі морського льоду за кожен місяць, із зазначенням року, коли були зафіксовані найвищі та найнижчі значення за період з жовтня 1978 року по травень 2019 року.

Щоб детальніше розглянути проблему зміни площі морського льоду, виконаємо апроксимацію та побудуємо прямі лінії, які продемонструють основні тенденції (рис. 4, 5). Розраховані кути між отриманими прямими лініями та віссю часу наведено в таблиці 2.

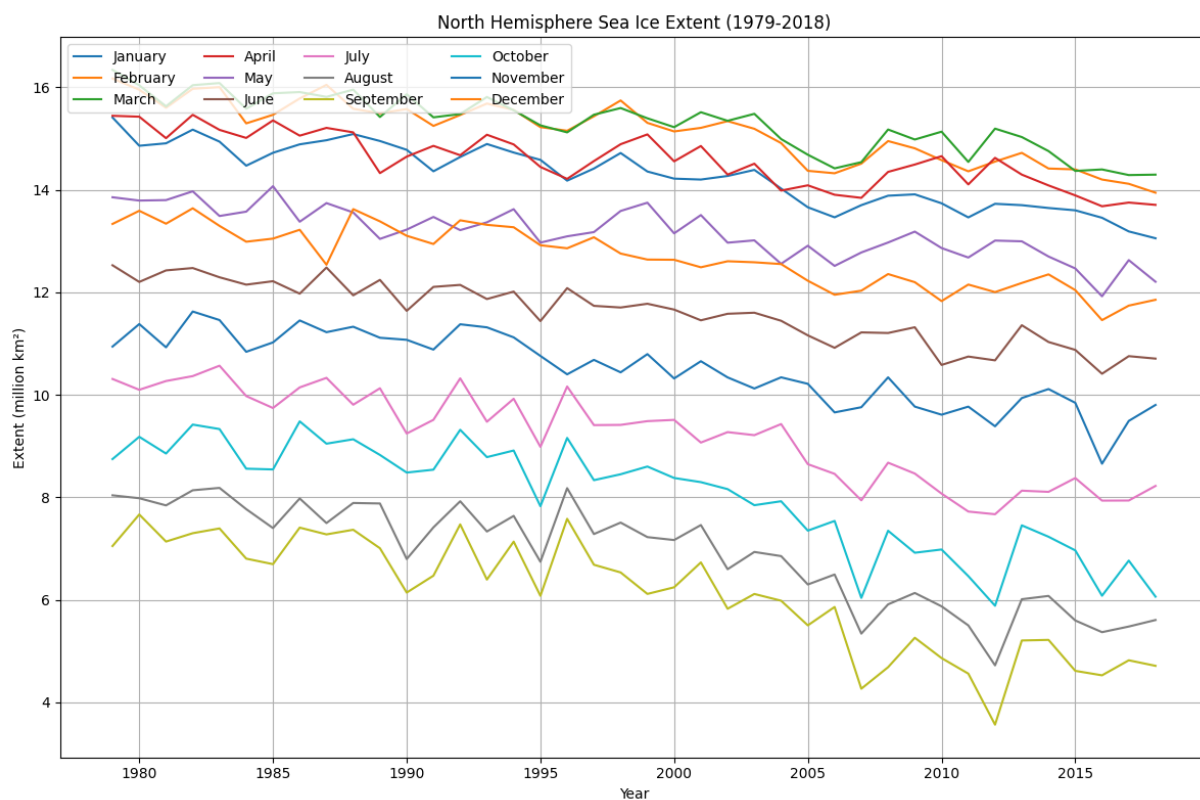


Рисунок 2. Середня щомісячна площа морського льоду за роками в Північній півкулі




Рисунок 3. Середня щомісячна площа морського льоду за роками в Південній півкулі

Таблиця 1. Статистика площі поширення морського льоду (1978 – 2019)

Місяць	Площа поширення в Північній півкулі (10 ⁶ км ²)			Площа поширення в Південній півкулі (10 ⁶ км ²)		
	Min (Рік)	Max (Рік)	Середнє	Minimum (Рік)	Maximum (Рік)	Середнє
Січень	12.491 (2018)	15.912 (1979)	14.18	2.514 (2017)	9.393 (2015)	5.00
Лютий	13.741 (2018)	16.579 (1979)	15.04	2.112 (2017)	4.52 (2014)	3.07
Березень	14.041 (2019)	16.635 (1979)	15.21	2.08 (2017)	6.481 (2014)	4.04
Квітень	12.933 (2016)	15.945 (1982)	14.48	3.653 (2017)	10.164 (2015)	6.88
Травень	11.132 (2016)	14.786 (1982)	13.07	7.119 (2019)	12.979 (2014)	10.20
Червень	9.231 (2010)	13.091 (1982)	11.52	10.681 (1980)	16.306 (2014)	13.44
Липень	6.368 (2012)	11.562 (1979)	9.09	13.883 (2017)	18.16 (2014)	16.04
Серпень	3.648 (2012)	9.224 (1983)	6.78	16.315 (1986)	19.234 (2014)	17.79
Вересень	3.34 (2012)	8.211 (1996)	5.99	17.471 (1986)	20.201 (2014)	18.54
Жовтень	4.112 (2012)	10.615 (1982)	7.93	16.475 (1986)	19.67 (2014)	18.16
Листопад	7.219 (2016)	12.695 (1982)	10.45	11.749 (2016)	18.273 (2013)	15.86
Грудень	10.183 (2016)	14.585 (1978)	12.64	5.345 (2018)	14.879 (2010)	10.39

Результати показують, що у Північній півкулі спостерігається значне зменшення площі морського льоду, особливо у вересні та жовтні. Лінійні тенденції площі морського льоду для кожного місяця за роками показані на рисунку 4 для Північної півкулі та на рисунку 5 для Південної півкулі. Рисунки 5 та 6 показують, що площа морського льоду в Арктичному регіоні має тенденцію до зменшення, тоді як в Антарктичному регіоні спостерігалася стабільність показників з 1979 по 2019 рік.

Для визначення швидкості зміни площі морського льоду було проведено лінійну інтерполяцію та визначено кути нахилу до осі абсцис (таблиця 2).




Рисунок 4. Лінійні тенденції середньої щомісячної площі морського льоду за роками в Північній півкулі

На рисунку 6 показано розкладання часового ряду на основні компоненти: тренди, сезонність та залишки за вересень у Північній півкулі, коли спостерігається річний мінімум площі морського льоду. Випадкові значення залишків свідчать про те, що розкладання успішно виділило тренд та сезонність.




Рисунок 5. Лінійні тенденції середньої щомісячної площі морського льоду за роками в Південній півкулі

Результати тесту Дікі-Фуллера представлені в таблиці 3. Таким чином, часовий ряд для площі морського льоду в Північній півкулі є нестационарним. Часовий ряд для площі морського льоду в Південній півкулі є стационарним.

На рисунку 6 показано розкладання часового ряду на основні компоненти: тренди, сезонність та залишки за вересень у Північній півкулі.

Для кращого розуміння закономірностей та виявлення аномалій у даних було проведено кластерний аналіз з використанням методів навчання без учителя.

Результат кластеризації К-середніх для Південної півкулі показує три окремі кластери (Рисунок 7).

У Південній півкулі результати кластеризації К-середніх показують інші закономірності (Рисунок 8) порівняно з Північною півкулею.

Таблиця 2. Кути нахилу загальних лінійних трендів до осі часу (1979 – 2019)

Місяць	Кут для Північної півкулі	Кут для Південної півкулі
Січень	-2.77°	0.66°
Лютий	-2.69°	0.28°
Березень	-2.41°	0.65°
Квітень	-2.15°	0.89°
Травень	-2.03°	0.98°
Червень	-2.72°	0.96°
Липень	-3.93°	0.76°
Серпень	-4.27°	0.64°
Вересень	-4.71°	0.58°
Жовтень	-4.51°	0.66°
Листопад	-3.06°	0.04°
Грудень	-2.61°	0.18°

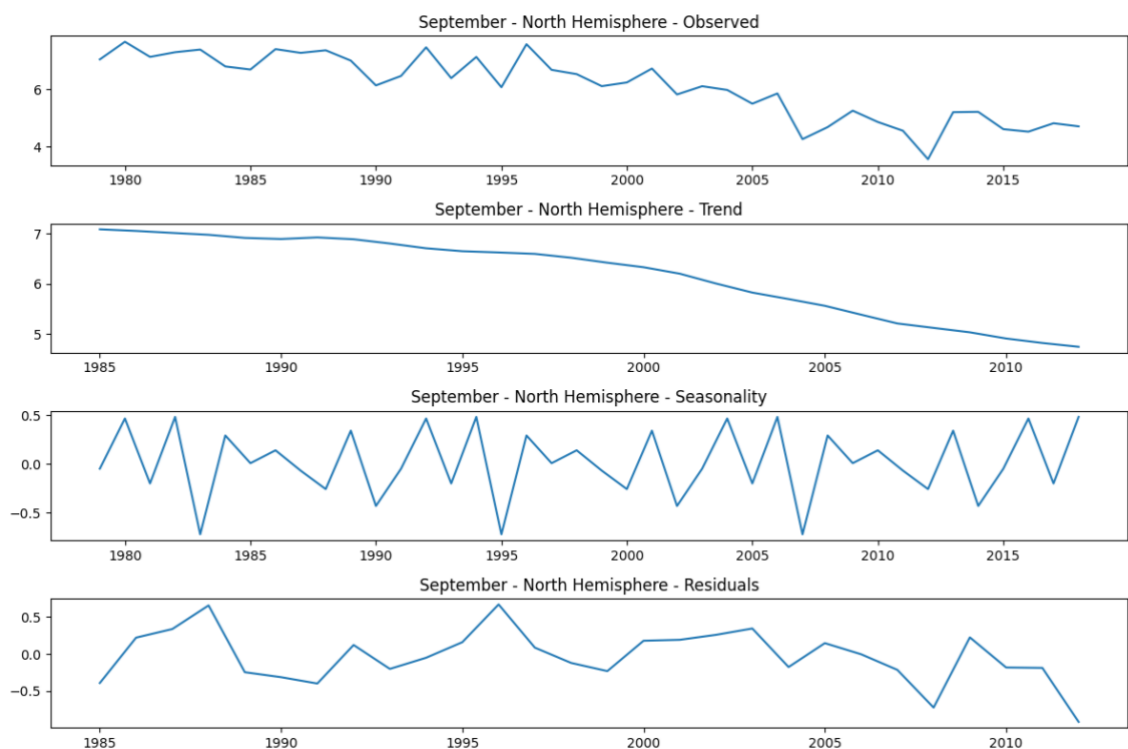


Рисунок 6. Розкладання даних часових рядів у Північній півкулі за вересень

Таблиця 3. Результати тесту Дікі-Фуллера

Змінна		Значення	
		Північна півкуля	Південна півкуля
Test Statistic		-1.026961129357658	-3.4720939348440467
p-value		0.7433042931743226	0.008733379945899898
Lags Used		12	15
Observations Used		475	472
Critical Values	1%	-3.4441920863262863	-3.444280551073031
	5%	-2.8676439813617147	-2.867682902679315
	10%	-2.570021186703601	-2.5700419306592934




Рисунок 7. Результат кластеризації К-середніх для Північної півкулі

Кластеризація, виконана за допомогою методу DBSCAN, не дала суттєвих результатів. Метод не розпізнавав відмінності, приписуючи всі значення одному кластеру для Північної (Рисунок 9) та Південної (Рисунок 10) півкуль. Цей

результат вказує на те, що аномальних значень у значеннях обох півкуль не було виявлено.

Ієрархічна кластеризація для Північної півкулі (Рисунок 11) виявляє три кластери.




Рисунок 8. Результат кластеризації К-середніх для Північної півкулі




Рисунок 9. Результат кластеризації DBSCAN для Північної півкулі




Рисунок 10. Результат кластеризації DBSCAN для Південної півкулі




Рисунок 11. Результат ієрархічної кластеризації для Північної півкулі

Результати ієрархічної кластеризації для Південної півкулі представлені на рисунку 12. Виявлено три кластери.

Кластерний аналіз показує, що площа антарктичного морського льоду має складні закономірності та потенційно деякі приховані закономірності. Цей регіон потребує детальнішого вивчення. Площа арктичного морського льоду

зменшується щороку швидше, і необхідні термінові дії, щоб уникнути негативних наслідків.

На основі статистичного та інтелектуального аналізу даних можна сформулювати гіпотезу.

Гіпотеза. Часовий ряд площі морського льоду в Північній півкулі є нестационарним і демонструє чітку тенденцію до зниження. Таким чином, доцільно прогнозувати дані за допомогою класичних методів авторегресії з урахуванням сезонних закономірностей. Водночас часовий ряд, що відповідає площі морського льоду в Південній півкулі, є стаціонарним і може містити приховані закономірності. Доцільно використовувати підходи машинного навчання для прогнозування даних.

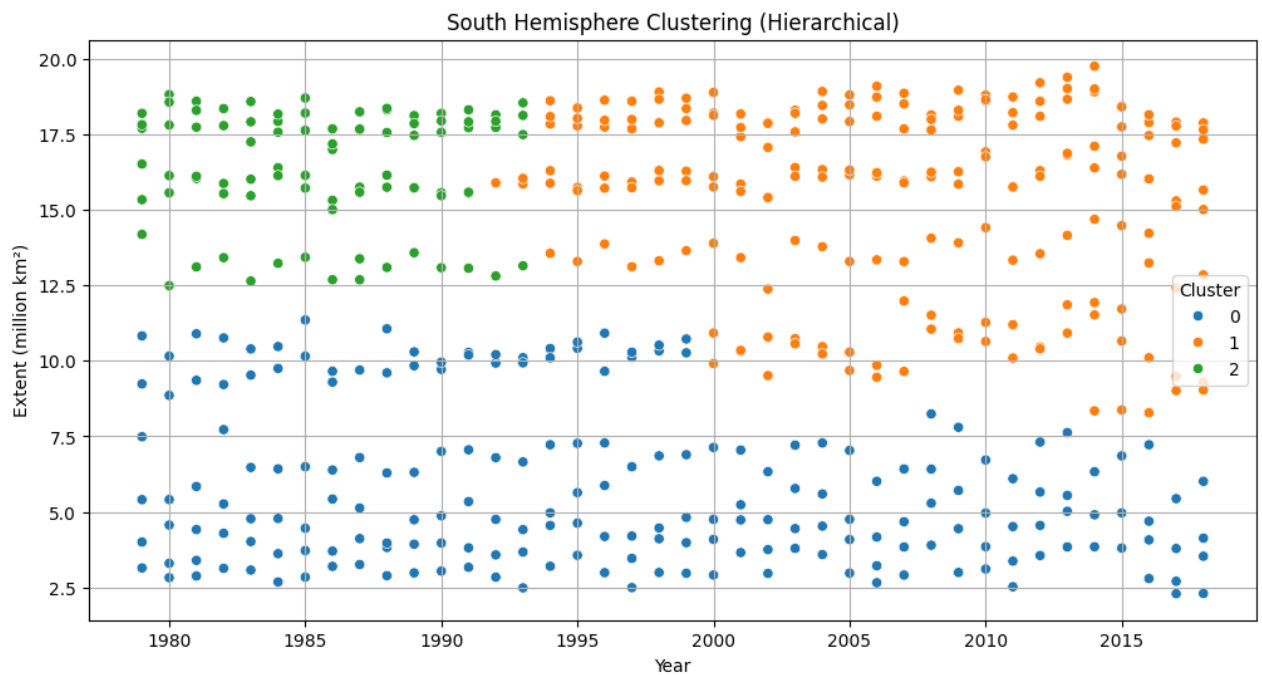


Рисунок 12. Результат ієрархічної кластеризації для Південної півкулі

Для перевірки гіпотези ми розглянемо такі методи прогнозування: SARIMA, LSTM, Bi-LSTM та ансамблеві моделі, що поєднують SARIMA з LSTM та Bi-LSTM.

Через брак даних довгострокових спостережень можливо оцінити лише короткостроковий прогноз.

На рисунках 13-17 показано оцінку методів прогнозування на валідаційному наборі для Північної півкулі.




Рисунок 13. Оцінка прогнозу SARIMA для Північної півкулі




Рисунок 14. Оцінка прогнозу LSTM для Північної півкулі




Рисунок 15. Оцінка прогнозу Bi-LSTM для Північної півкулі




Рисунок 16. Оцінка прогнозу SARIMA+LSTM для Північної півкулі

На рисунку 18 та в таблиці 4 показано порівняння показників продуктивності моделей.




Рисунок 17. Оцінка прогнозу SARIMA+Bi-LSTM для Північної півкулі

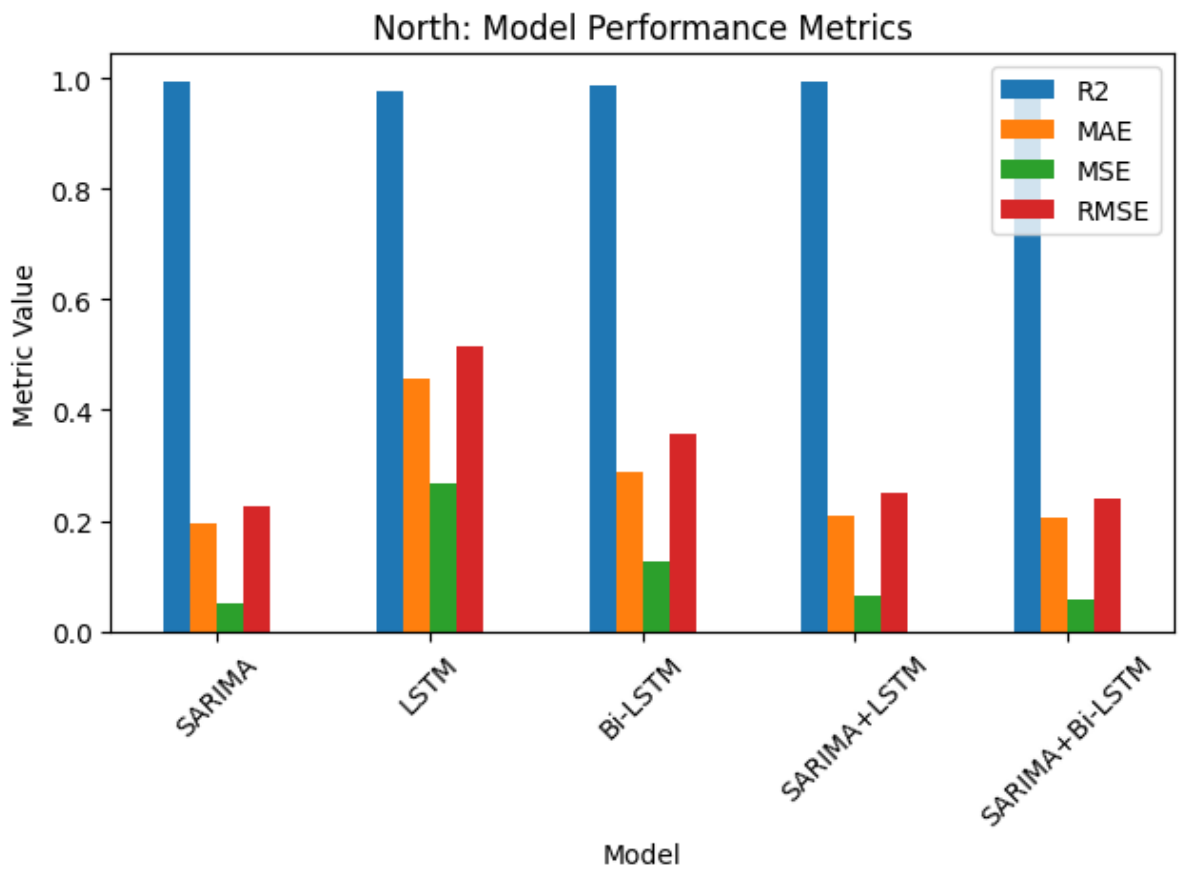


Рисунок 18. Показники продуктивності

Таблиця 4. Оцінка моделі для Північної півкулі

Модель	Метрики			
	R ²	MAE	MSE	RMSE
SARIMA	0.9953	0.1932	0.0512	0.2263
LSTM	0.9758	0.4557	0.2658	0.5156
Bi-LSTM	0.9884	0.2887	0.1275	0.3571
SARIMA+LSTM	0.9943	0.2078	0.063	0.251
SARIMA+Bi-LSTM	0.9948	0.205	0.0573	0.2393

Найкращу продуктивність продемонструвала модель SARIMA. Результат експерименту підтвердив першу частину сформуваної гіпотези, а саме, що для прогнозування часових рядів протяжності морського льоду в Північній півкулі доцільно використовувати класичні авторегресори з урахуванням сезонних закономірностей.

Візуалізація довгострокового прогнозу наведена на рис. 19.

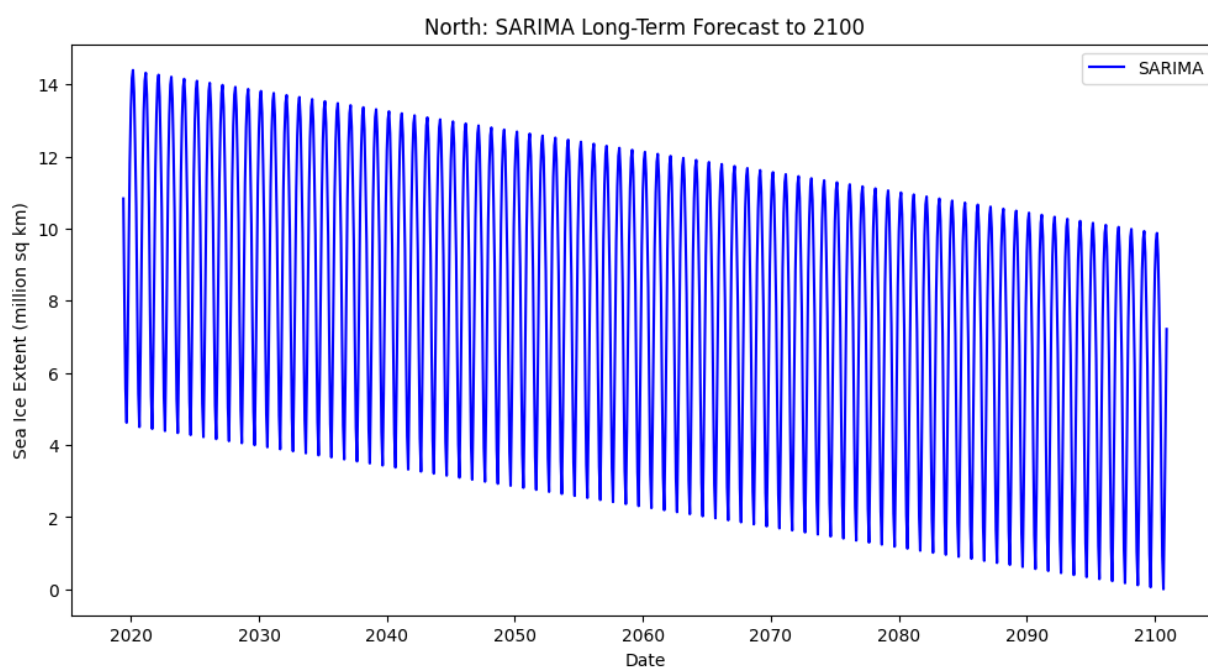


Рисунок 19. Довгостроковий прогноз SARIMA

На рисунках 20-24 показано оцінку методів прогнозування на валідаційному наборі для Південної півкулі.




Рисунок 20. Оцінка прогнозу SARIMA для Південної півкулі




Рисунок 21. Оцінка прогнозу LSTM для Південної півкулі




Рисунок 22. Оцінка прогнозу Bi-LSTM для Південної півкулі




Рисунок 23. Оцінка прогнозу SARIMA+LSTM для Південної півкулі

На рисунку 25 та в таблиці 5 показано порівняння показників ефективності моделей.




Рисунок 24. Оцінка прогнозу SARIMA+Bi-LSTM для Південної півкулі

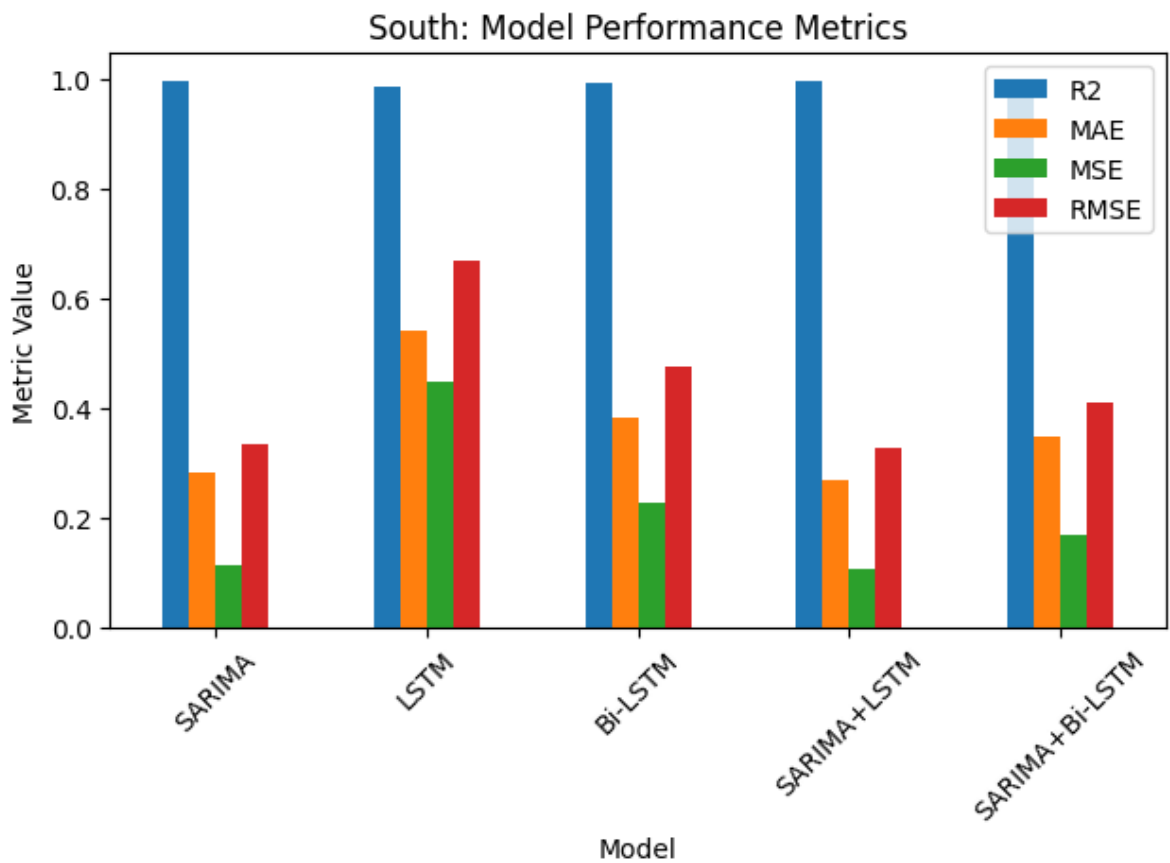


Рисунок 25. Показники продуктивності

Таблиця 5. Оцінка моделі для Південної півкулі

Модель	Метрики			
	R ²	MAE	MSE	RMSE
SARIMA	0.9965	0.2814	0.1119	0.3345
LSTM	0.986	0.5404	0.447	0.6686
Bi-LSTM	0.993	0.3827	0.2261	0.4755
SARIMA+LSTM	0.9967	0.2685	0.1069	0.327
SARIMA+Bi-LSTM	0.9948	0.3459	0.1674	0.4092

Найкращу продуктивність продемонструвала ансамблева модель SARIMA+LSTM. Результат експерименту підтвердив другу частину сформуваної гіпотези, а саме, що для прогнозування часових рядів протяжності морського льоду в Південній півкулі доцільно використовувати підхід машинного навчання для виявлення прихованих закономірностей.

Візуалізація довгострокового прогнозу показана на рис. 26.

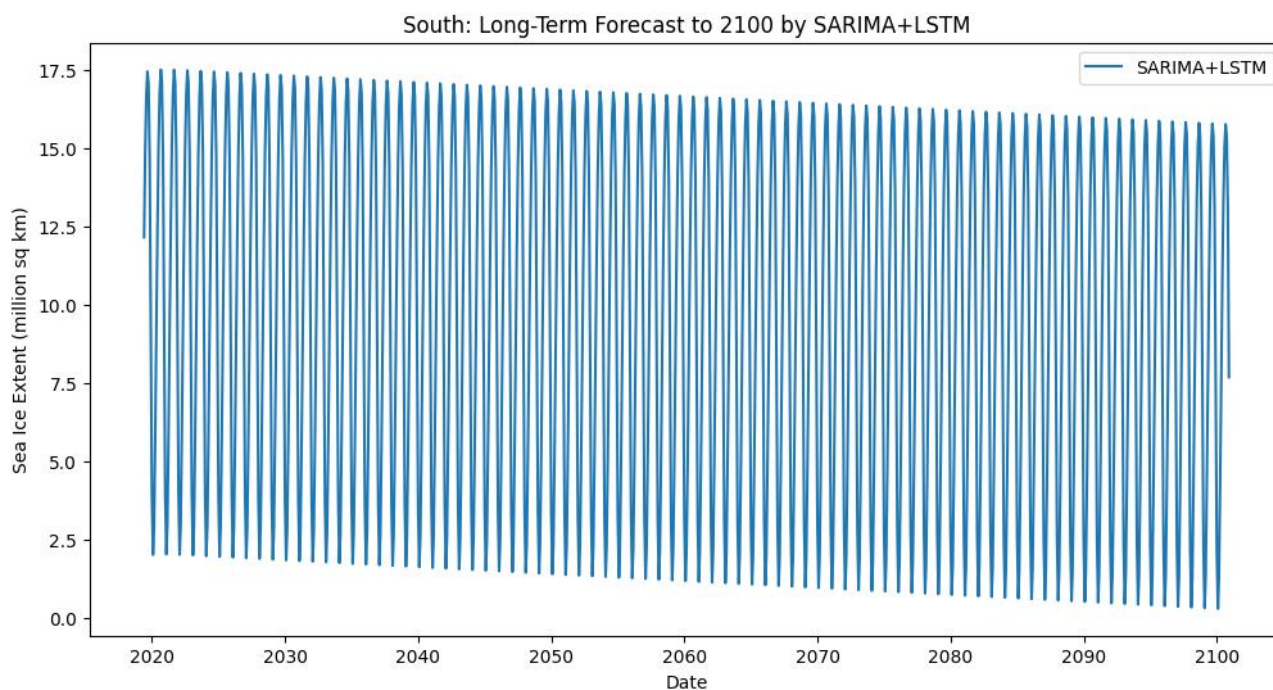


Рисунок 26. Довгостроковий прогноз SARIMA

V. Впровадження

Для реалізації моделі та її представлення широкому колу користувачів було розроблено веб-орієнтовану інформаційну систему. На рисунку 27 зображено головний екран інформаційної системи. На рисунку 28 зображено вікно введення параметрів. На рисунках 29-31 показано виведення результатів. Розроблена інформаційна система дозволяє не лише переглядати дані спостережень та прогнозів, але й порівнювати показники за різні роки, що особливо корисно для наукових та освітніх цілей.




Рисунок 27. Головний екран

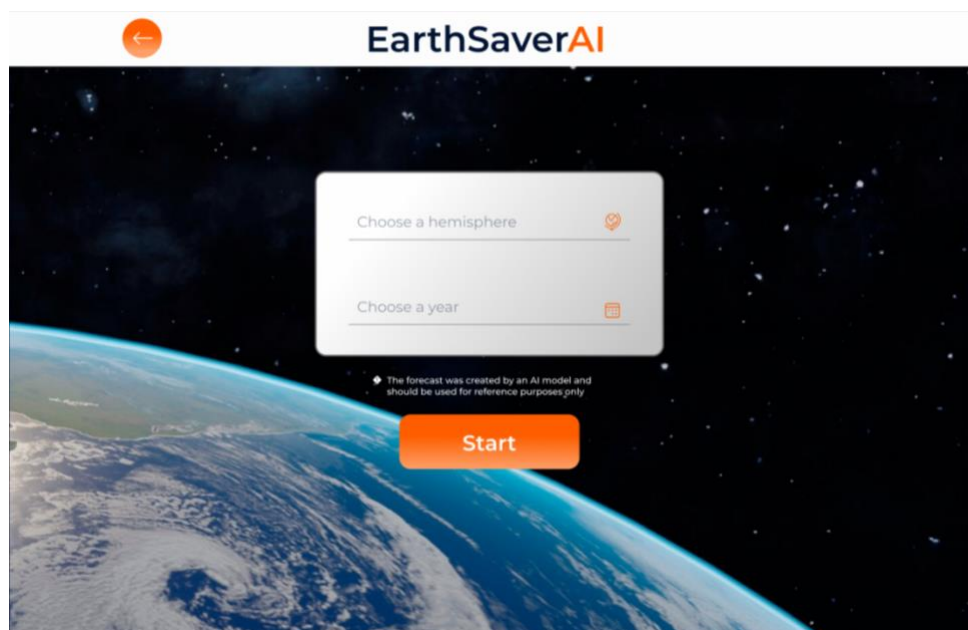


Рисунок 27. Екран вибору

EarthSaverAI



Рисунок 29. Результати у табличному представленні

EarthSaverAI

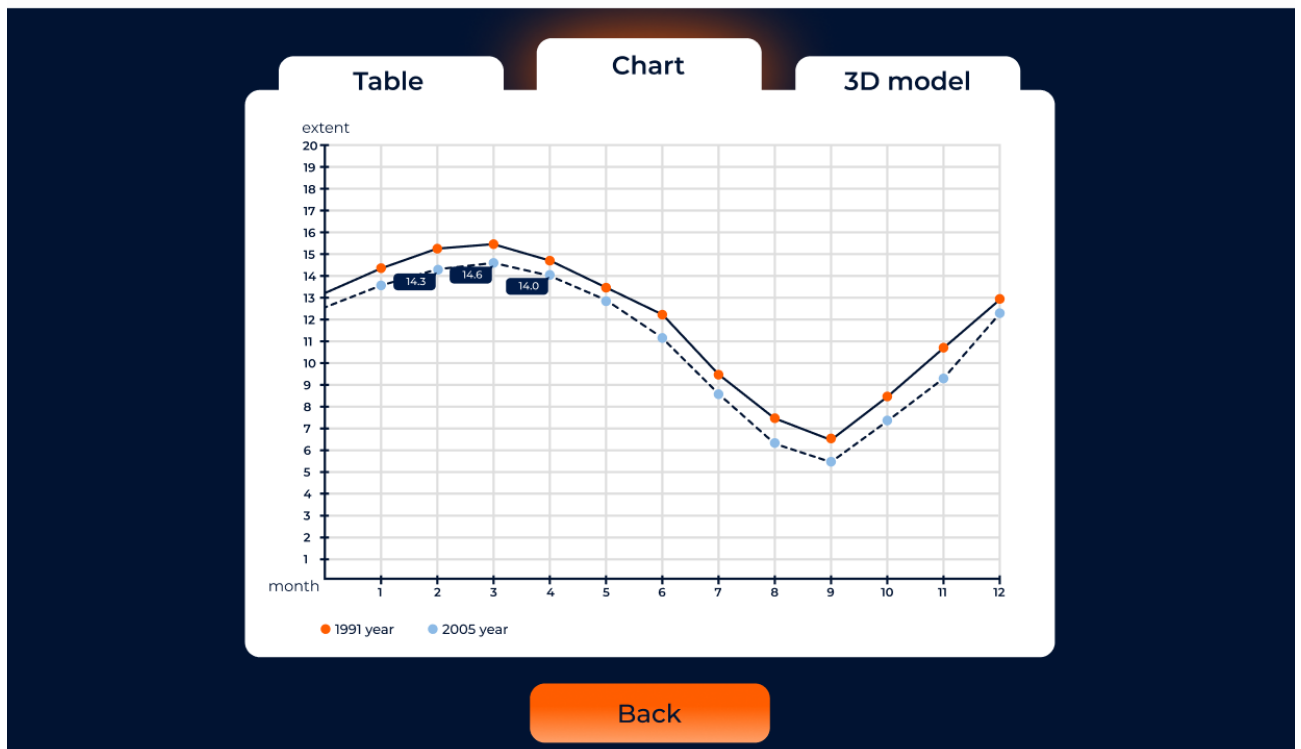


Рисунок 30. Результати в графічному представленні

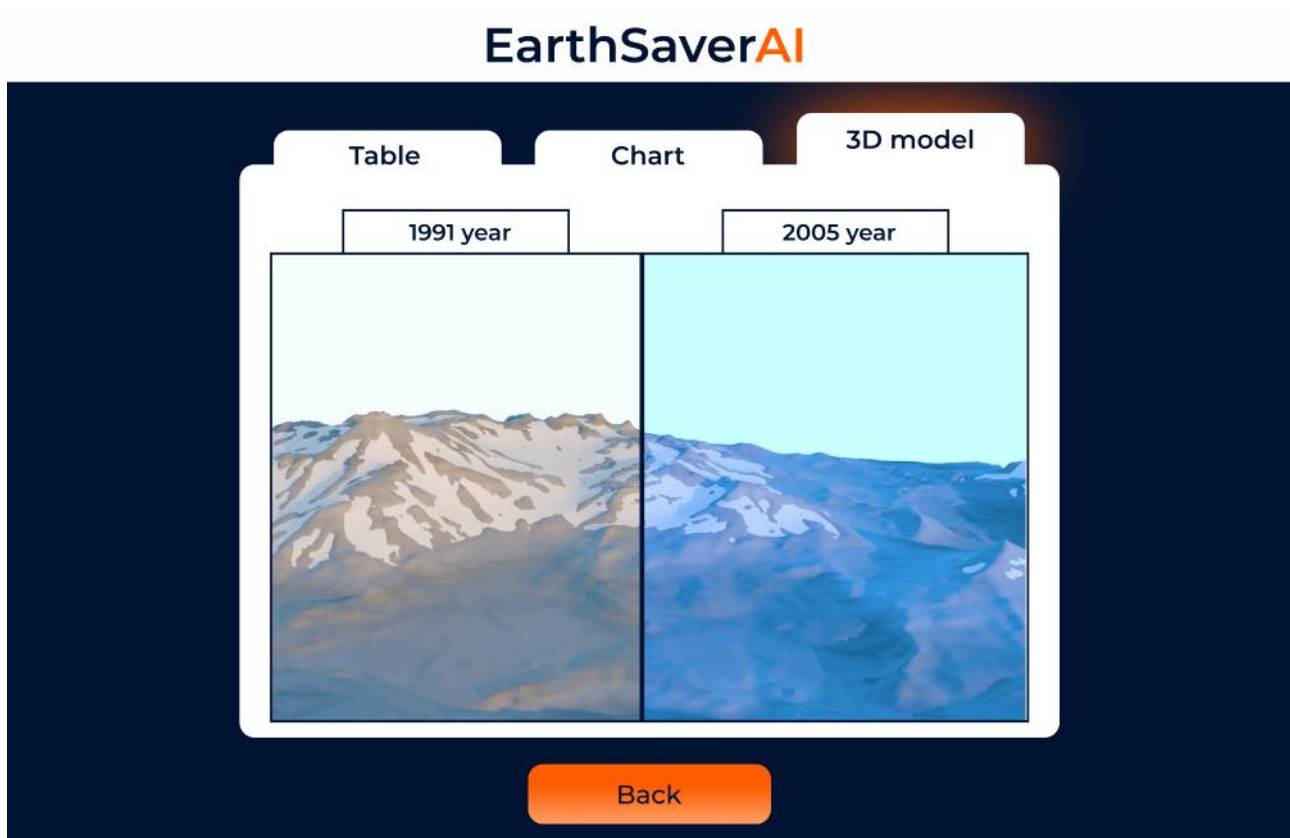


Рисунок 31. Візуалізація танення льоду та снігу в прибережних регіонах

V. Використані джерела

[1] World Meteorological Organization. (2025). <https://wmo.int>

[2] Turner, J., Holmes, C., Harrison, T. C., Phillips, T., Jena, B., Reeves-Francois, T., Fogt, R., Thomas, E. R., & Bajish, C. C. (2022). Record low Antarctic Sea ice cover in February 2022. *Geophysical Research Letters*, 49(12). <https://doi.org/10.1029/2022gl098904>

[3] UNCC Learn. Resource Guide for Advanced Learning on predicting and projecting climate change. URL: https://www.uncclearn.org/wp-content/uploads/library/resource_guide_predicting_and_projecting_climate_change.pdf

[4] ...

... *Science and technology today*

2024 ...

[5] United Nations. Transforming our world: the 2030 Agenda for Sustainable Development. [Online]. URL: <https://sdgs.un.org/2030agenda>

[6] ...2024

...

Computer Systems and Information Technologies ...

[7] ...

...

... CEUR-WS. (2025). ...

[8] ... (2024). ...

...

Computer Systems and Information Technologies, ...

[9] ...

... (2024). ...

... Computer Systems and Information Technologies, ...

[10] Chen, X., Wen, Z., Song, Y., & Guo, Y. (2022). Causes of extreme 2020 Meiyu-Baiu rainfall: a study of combined effect of Indian Ocean and Arctic. *Climate Dynamics*, 59(11–12), 3485–3501. <https://doi.org/10.1007/s00382-022-06279-0>

[11] Müller, M., Kelder, T., & Palerme, C. (2022). Decline of sea-ice in the Greenland Sea intensifies extreme precipitation over Svalbard. *Weather and Climate Extremes*, 36, 100437. <https://doi.org/10.1016/j.wace.2022.100437>

[12] Sundaram, S., & Holland, D. M. (2022). A physical mechanism for the Indian summer Monsoon—Arctic Sea-Ice teleconnection. *Atmosphere*, 13(4), 566. <https://doi.org/10.3390/atmos13040566>

[13] Zhou, B., Xu, M., Sun, B., Han, T., & Cheng, Z. (2020). Possible role of Southern Hemispheric sea ice in the variability of West China autumn rain. *Atmospheric Research*, 249, 105329. <https://doi.org/10.1016/j.atmosres.2020.105329>

[14] Henke, M., Miesse, T., De Souza De Lima, A., Ferreira, C. M., & Ravens, T. M. (2024). Increasing coastal exposure to extreme wave events in the Alaskan Arctic

as the open water season expands. *Communications Earth & Environment*, 5(1).
<https://doi.org/10.1038/s43247-024-01323-9>

[15] The cryosphere is the frozen water part of the Earth system. (2025).
<https://oceanservice.noaa.gov/facts/sea-ice-climate.html>

[16] Fretwell, P. T. (2024). A 6 year assessment of low sea-ice impacts on emperor penguins. *Antarctic Science*, 36(1), 3–5. doi:10.1017/S0954102024000130.

[17] Lee, J. R., Waterman, M. J., Shaw, J. D., Bergstrom, D. M., Lynch, H. J., Wall, D. H., & Robinson, S. A. (2022). Islands in the ice: Potential impacts of habitat transformation on Antarctic biodiversity. *Global Change Biology*, 28(20), 5865–5880.
<https://doi.org/10.1111/gcb.16331>

[18] Robinson, S. A., Revell, L. E., Mackenzie, R., & Ossola, R. (2024). Extended ozone depletion and reduced snow and ice cover – Consequences for Antarctic biota. *Global Change Biology*, 30(4). <https://doi.org/10.1111/gcb.17283>

[19] H. Cao, Y. Zhou, X. Jia and Y. Li, "Analysis of Sea Ice Area Fluctuation in the Arctic Circle Based on Big Data and SARIMA Model," 2024 International Conference on Electrical Drives, Power Electronics & Engineering (EDPEE), Athens, Greece, 2024, pp. 376-380, doi: 10.1109/EDPEE61724.2024.00077.

[20] Seo, M., & Kim, H.-C. (2024). Arctic Greening Trends: Change Points in Satellite-Derived Normalized Difference Vegetation Indexes and Their Correlation with Climate Variables over the Last Two Decades. *Remote Sensing*, 16(7), 1160.
<https://doi.org/10.3390/rs16071160>

[21] Kocsis, T., Pongrácz, R., Hatvani, I. G., Magyar, N., Anda, A., & Kovács-Székely, I. (2024). Seasonal trends in the Early Twentieth Century Warming (ETCW) in a centennial instrumental temperature record from Central Europe. *Hungarian Geographical Bulletin*, 73(1), 3–16. <https://doi.org/10.15201/hungeobull.73.1.1>

[22] Huo, X., Sun, N., & Ma, L. (2024). MA-BLTSI model for Land Surface Temperature prediction based on multi-dimensional data. *Theoretical and Applied Climatology*, 155(7), 6119–6136. <https://doi.org/10.1007/s00704-024-05009-2>

[23] Dixit, S., & Pandey, K. K. (2024). Spatiotemporal variability identification and analysis for non-stationary climatic trends for a tropical river basin of India.

Journal of Environmental Management, 365, 121692.
<https://doi.org/10.1016/j.jenvman.2024.121692>

[24] Ng, J. L., Huang, Y. F., Yong, S. L. S., Lee, J. C., Ahmed, A. N., & Mirzaei, M. (2024). Analysing the variability of non-stationary extreme rainfall events amidst climate change in East Malaysia. *AQUA – Water Infrastructure Ecosystems and Society*, 73(7), 1494–1509. <https://doi.org/10.2166/aqua.2024.132>

[25] Islam, M. T., Kamal, A. S. M. M., Islam, M. M., & Hossain, S. (2024). Impact of climate change on dengue incidence in Singapore: time-series seasonal analysis. *International Journal of Environmental Health Research*, 34(12), 3988–3998. <https://doi.org/10.1080/09603123.2024.2337827>

[26] Palerme, C., Lavergne, T., Rusin, J., Melsom, A., Brajard, J., Kvanum, A. F., Sørensen, A. M., Bertino, L., & Müller, M. (2024). Improving short-term sea ice concentration forecasts using deep learning. *The Cryosphere*, 18(4), 2161–2176. <https://doi.org/10.5194/tc-18-2161-2024>

[27] Li, W., Hsu, C., & Tedesco, M. (2024). Advancing Arctic Sea Ice Remote Sensing with AI and Deep Learning: Opportunities and Challenges. *Remote Sensing*, 16(20), 3764. <https://doi.org/10.3390/rs16203764>

[28] H. Cao, Y. Zhou, X. Jia and Y. Li, "Analysis of Sea Ice Area Fluctuation in the Arctic Circle Based on Big Data and SARIMA Model," 2024 International Conference on Electrical Drives, Power Electronics & Engineering (EDPEE), Athens, Greece, 2024, pp. 376-380, doi: 10.1109/EDPEE61724.2024.00077.

[29] Ahanda, B., Yolcu, T. & Watson, R. Forecasting arctic sea ice extent trend using time series models: NNAR, SARIMA and SARIMAX using the data prior to the COVID-19 pandemic. *Discov Geosci* 3, 18 (2025). <https://doi.org/10.1007/s44288-025-00113-w>

[30] A'an Johan Wahyudi, Febty Febriani, Time-series forecasting of particulate organic carbon on the Sunda Shelf: Comparative performance of the SARIMA and SARIMAX models, *Regional Studies in Marine Science*, Volume 80, 2024, 103863, ISSN 2352-4855, <https://doi.org/10.1016/j.rsma.2024.103863>

- [31] Song, C., Zhu, J. & Li, X. Assessments of Data-Driven Deep Learning Models on One-Month Predictions of Pan-Arctic Sea Ice Thickness. *Adv. Atmos. Sci.* 41, 1379–1390 (2024). <https://doi.org/10.1007/s00376-023-3259-3>
- [32] Zaatar, T., Cheaitou, A., Faury, O. et al. Arctic sea ice thickness prediction using machine learning: a long short-term memory model. *Ann Oper Res* 345, 533–568 (2025). <https://doi.org/10.1007/s10479-024-06457-9>
- [33] Gao, B., Liu, Y., Lu, P., Wang, L., & Liao, H. (2025). Advancing Sea Ice Thickness Hindcast with Deep Learning: A WGAN-LSTM Approach. *Water*, 17(9), 1263. <https://doi.org/10.3390/w17091263>
- [34] Pegkou Christofi, V. and Wang, X.D. (2024) Optimizing the LSTM Deep Learning Model for Arctic Sea Ice Melting Prediction. *Atmospheric and Climate Sciences*, 14, 429-449. doi: 10.4236/acs.2024.144026.
- [35] P. Scala, G. Manno, E. Ingrassia, G. Ciraolo, Combining Conv-LSTM and wind-wave data for enhanced sea wave forecasting in the Mediterranean Sea, *Ocean Engineering*, Volume 326, 2025, 120917, ISSN 0029-8018, <https://doi.org/10.1016/j.oceaneng.2025.120917>
- [36] Xiaoran Dong, Qinghua Yang, Yafei Nie, Lorenzo Zampieri, Jiuke Wang, Jiping Liu, Dake Chen, Antarctic sea ice prediction with A convolutional long short-term memory network, *Ocean Modelling*, Volume 190, 2024, 102386, ISSN 1463-5003, <https://doi.org/10.1016/j.ocemod.2024.102386>
- [37] Hussain, A., & Ravikumar, G. (2025). Multi-Scale Temporal Feature Learning for Wind Power Forecasting Using Bayesian Optimized Deep Neural Networks with Uncertainty Quantification. *TechRxiv*. <https://doi.org/10.36227/techrxiv.172425846.67224743/v2>
- [38] Mohamad Mazen Hittawe, Fouzi Harrou, Mohammed Amine Togou, Ying Sun, Omar Knio, Time-series weather prediction in the Red sea using ensemble transformers, *Applied Soft Computing*, Volume 164, 2024, 111926, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2024.111926>
- [39] *Daily Sea Ice extent Data*. (2019, June 10). Kaggle. <https://www.kaggle.com/datasets/nsidcorg/daily-sea-ice-extent-data>

- [40] *National Snow and Ice Data Center*. (2025, May 14). <https://nsidc.org/home>
- [41] Korstanje, J. (2023, July 31). How to select a model for your Time Series Prediction Task [Guide]. neptune.ai. <https://neptune.ai/blog/select-model-for-time-series-prediction-task>
- [42] Duan, H., Li, Q., He, L., Zhang, J., An, H., Ali, R., & Vazifiedoust, M. (2024). Climate classification for major cities in China using cluster analysis. *Atmosphere*, 15(7), 741. <https://doi.org/10.3390/atmos15070741>.
- [43] Sun, K., Lan, T., Goh, Y. M., Safiena, S., Huang, Y., Lytle, B., & He, Y. (2023). An interpretable clustering approach to safety climate analysis: Examining driver group distinctions. *Accident Analysis & Prevention*, 196, 107420. <https://doi.org/10.1016/j.aap.2023.107420>
- [44] M. Ali, P. Scandurra, F. Moretti and H. H. R. Sherazi, “Anomaly Detection in Public Street Lighting Data Using Unsupervised Clustering,” in *IEEE Transactions on Consumer Electronics*, vol. 70, no. 1, pp. 4524-4535, Feb. 2024, doi: 10.1109/TCE.2024.3354189.
- [45] Suyal, M., & Sharma, S. (2024). A Review on Analysis of K-Means Clustering Machine Learning Algorithm based on Unsupervised Learning. *Journal of Artificial Intelligence and Systems*, 6(1), 85–95. <https://doi.org/10.33969/ais.2024060106>.
- [46] Aurangzeb, K. (2024). DBSCAN-based energy users clustering for performance enhancement of deep learning model. *Journal of Intelligent & Fuzzy Systems*, 46(3), 5555–5573. <https://doi.org/10.3233/jifs-235873>.
- [47] Mavaluru, D., Malar, R. S., Dharmarajlu, S. M., Auguskani, J. P. L., & Chellathurai, A. (2024). Deep hierarchical cluster analysis for assessing the water quality indicators for sustainable groundwater. *Groundwater for Sustainable Development*, 25, 101119. <https://doi.org/10.1016/j.gsd.2024.101119>
- [48] Waqas, M., & Humphries, U. W. (2024). A Critical review of RNN and LSTM variants in hydrological Time Series predictions. *MethodsX*, 13, 102946. <https://doi.org/10.1016/j.mex.2024.102946>

[49] GeeksforGeeks. (2024, June 10). What is LSTM Long Short Term Memory? GeeksforGeeks. <https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/>

[50] J. Chen. Analysis of Statistic Metrics in Different Types of Machine Learning. *Highlights in Science, Engineering and Technology*, 88, pp. 182–188. (2024). <https://doi.org/10.54097/c4mz2q66>

[51] V. Plevris, G. Solorzano, N. Bakas, M. Ben Seghier. Investigation of performance metrics in regression analysis and machine learning-based prediction models. The 8th European Congress on Computational Methods in Applied Sciences and Engineering ECCOMAS Congress 2022. 5 – 9 June 2022, Oslo, Norway. (2022). <https://doi.org/10.23967/eccomas.2022.155>