

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ТЕХНОЛОГІЙ ТА ДИЗАЙНУ
Факультет ринкових, інформаційних та інноваційних технологій
Кафедра інформаційно-комп'ютерних технологій
та фундаментальних дисциплін

Дипломна магістерська робота

на тему:

«ПРОГНОЗНА МОДЕЛЬ НА БАЗІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ»

Виконала: студентка групи МгЧКІ-20
спеціальності
123 «Комп'ютерна інженерія»
ЛИПОВА Ольга

Керівник: к.т.н., доцент
ОДОКІЄНКО Світлана

Рецензент: _____

Черкаси – 2021 року

ЗМІСТ

ВСТУП.....	7
РОЗДІЛ 1 АНАЛІЗ ПРОГНОЗНИХ МОДЕЛЕЙ В УКРАЇНІ ТА СВІТІ	9
1.1. Прогнозування метеорологічних прогнозів. Сучасний стан	9
1.2. Аналіз засобів і методів автоматизації короткострокового прогнозування	21
1.3. Модель підготовки даних для прогнозування метеорологічних параметрів	25
Висновок до 1 розділу	30
РОЗДІЛ 2 АНАЛІЗ АЛГОРИТМІВ ТА КОМП'ЮТЕРНЕ МОДЕЛЮВАННЯ ...	31
2.1. Обробка багатовимірного сигналу фільтром Хебба	31
2.2. Обчислювальний алгоритм попередньої підготовки даних	35
2.3. Самоорганізовані системи та навчання мережі.....	36
2.4. Опис алгоритму виявлення значимих метеорологічних параметрів	41
2.5. Комп'ютерне моделювання та аналіз нейронної мережі	42
2.6. Алгоритм квантування вектору навчання.....	48
2.7. Адаптивна класифікація множин.....	50
2.8. Ієрархічне квантування векторів	54
2.9. Відображення результатів аналізу.....	59
Висновок до 2 розділу	64
РОЗДІЛ 3 СТВОРЕННЯ МОДЕЛІ ПРОГНОЗУВАННЯ ПОГОДИ	65
3.1. Розробка оперативного прогнозування погоди на основі властивостей «потрійного входу» числових моделей	65
3.2. Сучасні проблеми і методи прогнозу погоди та аналізу в Україні	73

3.2.1. Розробка регіональних мезомасштабних моделей – шлях підвищення якості прогнозу	73
3.2.2. Мезомасштабне прогнозування як синтез моделі АПС та напівсферної прогностичної моделі	75
3.2.3. Застосування методів математичної статистики у задачі локального прогнозу погоди	77
3.3. Спрощення моделі короткотермінового прогнозу погоди	78
Висновок до 3 розділу	83
ЗАГАЛЬНІ ВИСНОВКИ.....	84
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	87

ВСТУП

Для побудови прогнозу основних метеорологічних параметрів (МП) у наукових працях вітчизняних та зарубіжних метеорологів досліджувалась кореляція метеорологічних даних (МД). Як метеорологічні параметри (МП) для оцінки кореляції розглядалися пошарова температура атмосфери, тиск, швидкість вітру, вологість, вміст озону, прозорість повітряного середовища, розподіл і склад хмарного шару, температура ґрунту, радіаційного фону і т.д.

Актуальність теми в тому, що на даний момент запропоновано низку математичних моделей задач прогнозу погоди та загальної циркуляції атмосфери та чисельних алгоритмів для їх вирішення. Разом з тим необхідно відзначити, що рівняння гідротермодинаміки атмосферних процесів настільки складні, що досі є необхідність розробки більш якісних алгоритмів, здатних з високою точністю описати широкий спектр задач динамічної метеорології та прогнозу погоди.

Саме тому, в даний час, найбільші труднощі становить підвищення точності прогнозування та спрощення алгоритму, що, безсумнівно, робить вирішення даного завдання актуальним.

Задачі дослідження:

- проведення аналізу засобів та методів реалізації прогнозування МП;
- побудування спрощеної моделі реалізації прогнозування МП;
- побудування та проведення навчання нейронної мережі;

Метою дослідження є методичне забезпечення оцінки ймовірності прогнозування МП із використанням нейромережових технологій.

Об'єктом дослідження є створення та навчання алгоритмом SOM спрощеної моделі для прогнозування основних метеорологічних параметрів.

Предметом дослідження є створення прогнозної моделі на базі штучних нейронних мереж.

Наукова новизна роботи полягає в дослідженні та створенні спрощеної та більш точної прогностичної моделі для прогнозування основних метеорологічних параметрів із використанням методів машинного навчання.

Практична цінність розробленої моделі полягає в тому, що вона дозволяє покращити якість існуючих прогностичних моделей. Також мною був вибраний більш відповідний алгоритм для навчання штучної нейронної мережі.

Апробація результатів магістерської роботи.

Публікація результати досліджень в даному напрямку були опубліковані в одній науковій праці: Прогнозна модель на базі штучних нейронних мереж / Одокієнко С.М., Люта М.В., Липова О.М. // Інноватика в освіті, науці та бізнесі: виклики та можливості : матеріали II Всеукраїнської конференції здобувачів вищої освіти і молодих учених (18 листопада 2021 р., м. Київ). – Київ : КНУТД, 2021.

РОЗДІЛ 1

АНАЛІЗ ПРОГНОЗНИХ МОДЕЛЕЙ В УКРАЇНІ ТА СВІТІ

1.1. Прогнозування метеорологічних прогнозів. Сучасний стан

На сьогоднішній день існують два основних методи наукового передбачення погоди: синоптичний і чисельний (гідродинамічний).

Синоптичний метод базується на побудові та аналізі синоптичних карт (рисунок 1.1), на яких виділяються окремі об'єкти (циклони, антициклони, атмосферні фронти і т.д.), кожному з яких властиві певні типи погодних умов.



Рисунок 1.1 – Синоптична карта фактичної погоди

Для побудови карт виконується збір МД з різних джерел (рисунок 1.2).




Рисунок 1.2 – Джерела метеоданих

Синоптичні карти підрозділяються на карти фактичної погоди і прогностичні. Синоптичні карти надають інформацію про погоду, яка була в дійсності на момент їх випуску, другі - про погоду, яка очікується в найближчому часі. Карти обох класів діляться на приземні і висотні (карти баричної топографії).

Можна виділити характерні особливості і відмінності підходів і методів оцінки в різних статистичних моделях побудови прогнозу з використанням оцінки основних МП (таблиця 1.1, рисунок 1.4).

Таблиця 1.1 – Порівняння методів прогнозування

Моделі прогнозування	Переваги	Недоліки
Регресивні моделі	Швидкість отримання результату; Доступність проміжних обчислень; Простота моделей; Різноманітність вирішуваних завдань.	Трудомісткість визначення параметрів; Можливість моделювання лише лінійних процесів; Складність визначення виду функціональної залежності.
Авторегресійні моделі	Швидкість отримання результату; Доступність проміжних обчислень; Простота моделей; Різноманітність вирішуваних завдань.	Трудомісткість визначення параметрів; Можливість моделювання лише лінійних процесів.
Моделі експоненціального згладжування	Простота моделей; Швидкість отримання результату; Рішення задач довгострокового прогнозування.	Відсутність гнучкості.
Нейромережеві моделі	Можливість моделювання не лінійних процесів; Адаптивність; Масштабованість; Різноманітність вирішуваних завдань.	Складність програмної реалізації; Відсутність проміжних обчислень; Високі вимоги до несуперечності навчальної вибірки.
Моделі на базі ланцюгів Маркова	Простота моделей.	Вузька застосовність моделей; Неможливість вирішення завдань прогнозування з довгою пам'яттю.

До класичних методів статистичного прогнозування можна віднести методи, побудовані на фіксуванні факту зміни того чи іншого метеорологічного показника, характерного для обраного регіону, з урахуванням його статистичної значущості.

Реалізація статистичних методів прогнозування неможлива без побудови розвиненої мережі станцій спостереження (наземного, морського і космічного базування) обладнаних численними датчиками і апаратурним аналізом даних, що надходять.

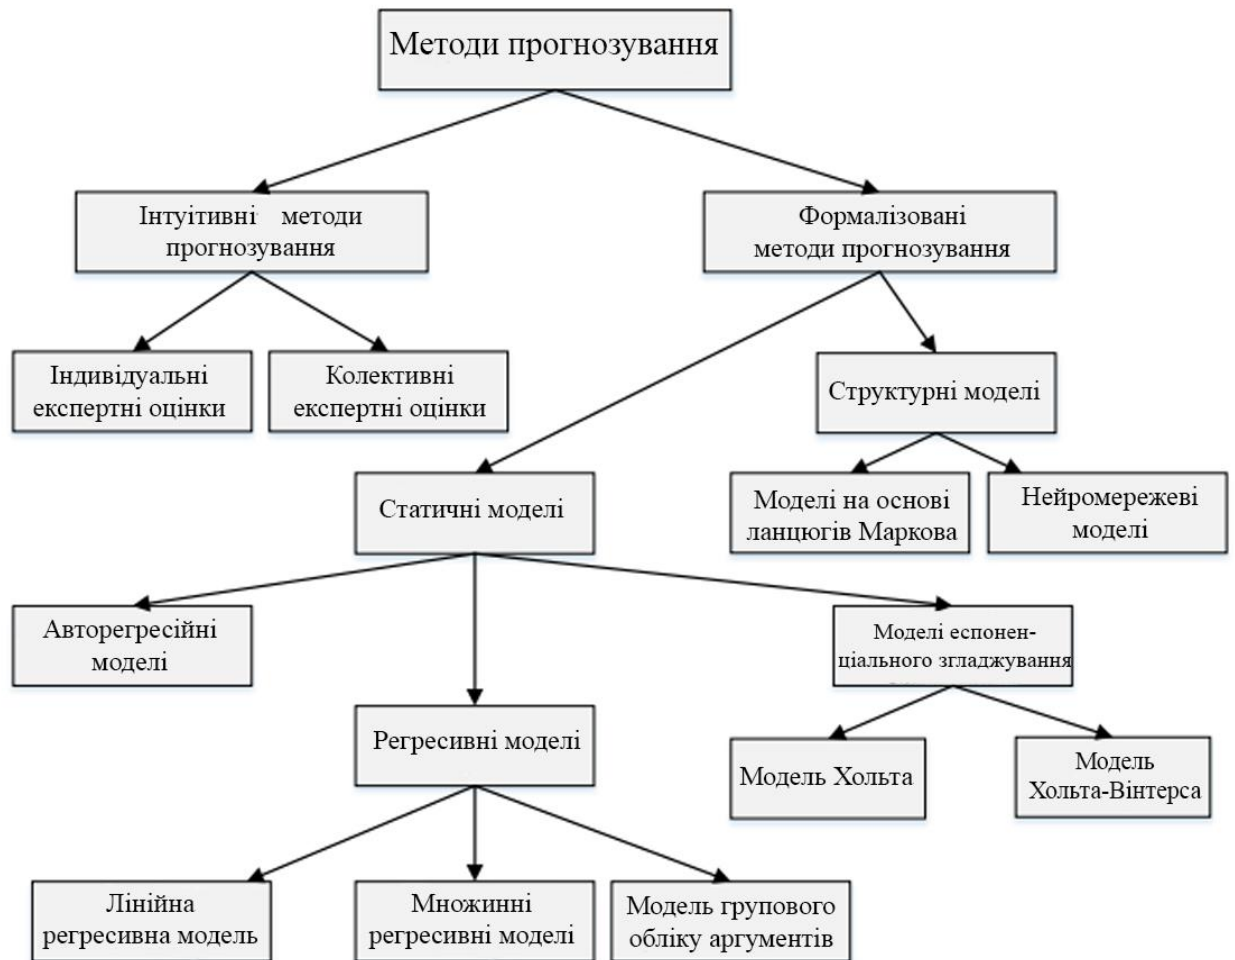


Рисунок 1.4 – Класифікація методів і моделей прогнозування

Необхідно також відзначити, що на сьогодні відсутня науково обґрунтована модель (методика), що дозволяє реалізувати навіть точний середньостроковий прогноз (час, місце, значення МП) яку б теорію (будови Землі, ймовірностей, математичної статистики, і т.д.), з використанням будь-якого математичного апарату (регресійного аналізу, статистичної оцінки, імовірнісного розподілу і т.д.),

грунтуючись на даних будь-яких спостереженнях (геолого-геофізичних, геохімічних, космічних і т.п.), вона б не використовувала.

Складнощами в реалізації точного прогнозу є дисперсія як самих МД, так і оцінка їх кореляції з МП, що проявляється як статистична неоднозначність і в локалізації місця, і в оцінці інтенсивності зміни, і у визначенні часу прогнозованого події.

Всі розглянуті методики побудовані на використанні очевидного факту, МД ретроспективного періоду відрізняються від МД реального періоду, необхідно тільки знайти дані відмінності, надати їм вагову характеристику, побудувати порогову шкалу і провести їх сукупну оцінку за критерієм перевищення встановленого порогу - реалізацію прогнозу, після реалізації прогнозу можна оцінити його точність порівнюючи з подіями, що реально спостерігаються. У тому випадку якщо збіги відбуваються з деякою ймовірністю, що перевищує статистичну помилку, можна зробити висновок про його спроможності. Для виявлення відмінностей ретроспективного і реальних періодів, можна використовувати широку базу багатокритеріальних даних, аналізованих, для виявлення статистичної значущості, ретроспективно.

Метеорологічні дані, що служать основою прогнозування зміни метеорологічних параметрів представлені на різних серверах і можуть аналізуватися практично в режимі онлайн.

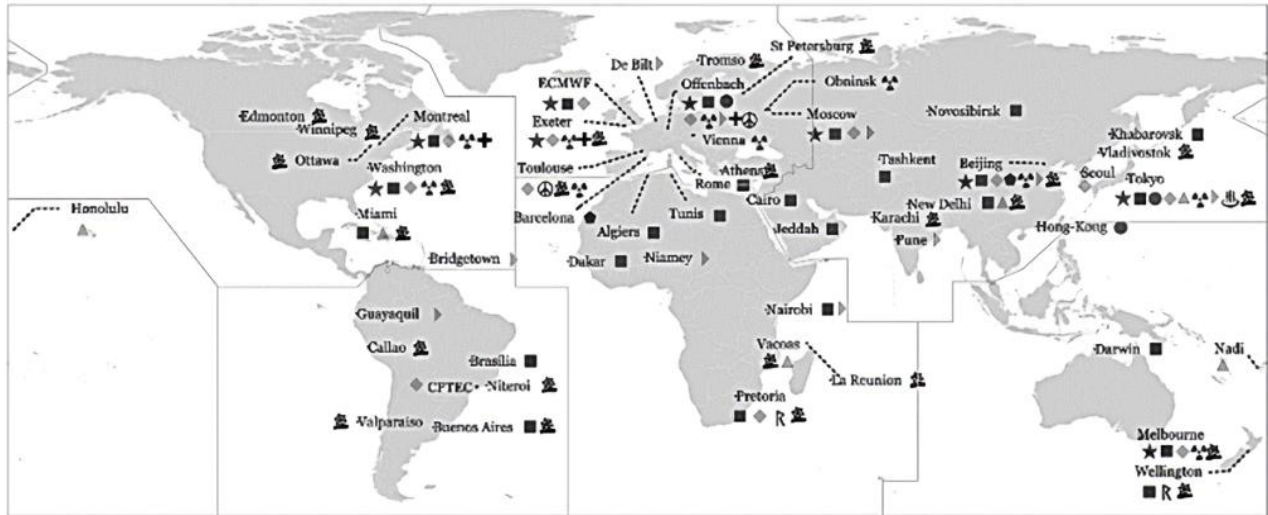
Наприклад, щільність розташування метеостанцій на території України, за даними, показано нарисунку 1.5.

Як приклад мережі різних датчиків і МД можна розглянути дані, що подаються Українським гідрометеорологічним центром.



Рисунок 1.5 – Розташування метеостанцій на території України

Розташування центрів обробки МД в світі, за даними показано на рисунку 1.6.



Legend

- ★ World Meteorological Centres* (9)
- ◆ Global Producing Centres for Long-Range Forecasts (13)
- ⊕ Global Producing Centres for Annual to Decadal Climate Prediction (3)
- RSMCs Geographic (25)
- RSMC Nowcasting (3)
- ▲ RSMCs TC (6)
- ◆ RSMCs Sand/Dust (2)
- ▶ Regional Climate Centres (11)
- ▲ RSMCs Nuclear Emergency Response** (10)
- ⊕ RSMCs Non-Nuclear Emergency Response** (2)
- ⚡ RSMCs Volcano Watch Services for International Air Navigation (1)
- R RSMCs Severe Weather Forecasting (2)
- ⚓ RSMCs Marine Meteorological Services (24)

* World Meteorological Centres are also Global Producing Centres for a) Deterministic Numerical Weather Prediction, b) Ensemble Numerical Weather Prediction, and c) Long-Range Forecasts.

** RSMC for nuclear and non-nuclear emergency response have Atmospheric Transport and Dispersion Modelling (ATDM) capabilities.

Рисунок 1.6 – Розташування центрів обробки метеоданих

У таблиці 1.2, показано, що знаходяться у відкритому доступі, дані спостережень, що надаються вищепереліченими джерелами.

Таблиця 1.2. Дані спостережень наземних станцій

№	Тип даних
1	Реєстрація варіацій і абсолютних значень компонент магнітного поля Землі
2	Електромагнітне вертикальне зондування іоносфери
3	Реєстрація координат геодезичного опорного пункту GPS, ГЛОНАСС
4	Метеорологічні дані (швидкість і напрям вітру і води, їх провідність, температура, тиск, вологість) і т.д.
5	Похиле зондування іоносфери по азимуту 20 градусів за допомогою радара СуперДАРН
6	Варіації гравіметричного поля. Гравіметр встановлений на пункт з абсолютною величиною поля, що виміряна.
	Температура і вологість приповерхневого шару ґрунту
	Радіаційний фон

Як приклад мережі різних датчиків, розташованих в акваторіях, можна розглянути дані, що подаються системою Samos [26] яка забезпечує регулярний доступ до точних, високоякісних морських метеорологічних і приповерхневих океанографічних спостереженням з дослідницьких суден і суден добровільних спостережень.

Як джерела відкритих геолого-геофізичних даних можуть також виступати: глобальні моделі електричного і магнітного поля; аномалії магнітного поля; аномалії гравітаційного поля; дані теплових потоків і т.п. У таблиці 1.3, показано дані спостережень системи Samos, що знаходяться у відкритому доступі.

Таблиця 1.3 – Дані спостережень станцій морського базування

№ п.п	Тип даних
1	Дані сонарів, ехолотів, доплеровських датчиків і гідрографічних сонарів
2	Метеорологічні дані (швидкість, напрям вітру і води, їх провідність, температура, тиск, вологість) і т.д.
3	Дані глибинних зондів (провідність води, температура і т.д.)
4	Коливання земної кори, води і повітря - механічні, оптичні, електромагнітні та ін.
5	Реєстрація високоточних координат геодезичного опорного пункту - GPS / WAAS, ГЛОНАСС, Galileo і ін.
6	Дані локального гравітаційного поля Землі
7	Сила і напрям локального магнітного поля Землі
8	Частка світла, поглинена або розсіяна частками в воді або повітрі

Значення основних МП ретроспективно, в прикордонному шарі атмосфери від поверхні землі до 2 км, після читання з масиву МД форматів АЕРОСТАБ і АЕРОСТАС, можна уявити в символічному форматі. МП містять статистики для висот: 0, 50, 100, далі з кроком 100 до 2000 м.

Файл даних для однієї станції містить тимчасової ряд щомісячних значень: середніх, середнькватратических відхилень і відповідного числа спостережень,

використаних для їх розрахунку. Формат запису для статистичних характеристик представлений в таблиці 1.4.

Таблиця 1.4 – Формат характеристик МП атмосфери

Знакова частина / МП / число спостережень	Позначення	Кількість цифр	Одиниці виміру	Константа відсутності
Індекс станції	INDEX	5	-	немає
Рік	GGGG	5	-	немає
Місяць	MM	3	-	немає
Тремін	HH	3	GMT	немає
Стандартне значення висоти	Z	6	м	немає
Середньомісячні значення тиску	MP	6	10·гПа	-9999
Середньоквадратичне відхилення тиску	SP	6	10·гПа	-9999
Число спостережень для тиску	NP	3	-	немає
Середньомісячні значення температури	MT	6	10·°C	-9999
Середньоквадратичне відхилення температури	ST	6	10·°C	-9999
Число спостережень для температури	NT	3	-	немає
Середньомісячні значення дефіциту точки роси	MD	6	10·°C	-9999
Середньоквадратичне відхилення дефіциту точки роси	SD	6	10·°C	-9999
Число спостережень для дефіциту точки роси	ND	3	-	немає
Середньомісячні значення скалярної швидкості вітру	MS	6	10·°C	-9999
Середньоквадратичне відхилення скалярної швидкості вітру	SS	6	10·°C	-9999
Число спостережень для скалярної швидкості вітру	NS	3	-	немає

Продовження таблиці 1.4

Середньомісячні значення зональної складової швидкості вітру	MU	6	10·°C	-9999
Середньоквадратичне відхилення зональної складової швидкості вітру	SU	6	10·°C	-9999
Число спостережень для зональної складової швидкості вітру	NU	3	-	немає
Середньомісячні значення меридіональної складової швидкості вітру	MV	6	10 · м / с	-9999
Среднеквадратические відхилення меридіональної складової швидкості вітру	SV	6	10 · м / с	-9999
Число спостережень для меридіональної складової швидкості вітру NV	3	3	-	немає

Приклад запису основних МП, за 10 років спостережень, в форматах Аеростан і АЕРОСТАС. Дані надані ЦЕНТРАЛЬНОЮ ГЕОФІЗИЧНОЮ ОБСЕРВАТОРІЄЮ імені Бориса, результати обробки даних показані в таблиці 1.5.

Таблиця 1.5 – Середні місячні температури повітря по м. Києву

Рік	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	I- XII
2011	-2.4	-6.1	1.5	10.2	16.7	21.1	21.7	19.3	15.8	7.7	2.4	2.2	9.2
2012	-4.0	-10.0	2.5	11.8	18.1	20.0	23.6	20.4	16.2	10.1	4.6	-5.0	9.0
2013	-4,3	-0,6	-1,7	10,3	18,9	21,6	20,8	19,9	12,4	9,7	6,4	-0,2	9,4
2014	-4,8	-0,5	6,8	10,3	16,9	18,2	22,1	21,3	15,3	7,7	1,7	-2,1	9,4
2015	-0,8	-0,7	5,1	9,7	16,0	20,4	21,9	22,6	17,8	7,3	4,7	1,9	10,5
2016	-5,7	2,0	3,9	12,4	15,5	20,6	22,4	21,1	16,1	6,5	1,2	-1,5	9,5
2017	-4,9	-2,8	6,2	10,4	15,2	20,0	20,9	22,4	16,4	8,4	3,3	1,6	9,8
2018	-2,4	-3,8	-1,9	13,1	18,8	20,6	21,4	22,5	17,3	10,7	0,3	-2,2	9,5
2019	-4,5	0,6	5,1	10,6	17,0	23,6	19,8	20,7	15,9	11,1	4,6	2,7	10,6
2020	0,8	2,5	6,5	9,9	12,4	21,7	21,9	21,4	18,4	12,5	3,8	-0,5	10,9

МД (показані частково) реального періоду (три доби) для зазначеної станції, можна отримати з різних погодних сервісів (таблиця 1.6, рисунок 1.5) або безпосередньо зі станції спостереження в форматі КН-03.

Таблиця 1.6 –Метеорологічні дані по Київській області

Метеостанція	Дата	Температура повітря	Вологість, %	Вітер, м/с	Атм. тиск мм.рт.ст.	Погода
Баришівка	20.10 15:00	13,8	61	↗ 3-9	757	значна хмарність
	20.10 09:00	1.7	81	↑ 1-3	760	мінлива хмарність
	19.10 21:00	-0.1	94	☀ 0-5	762	ясно
Біла Церква	20.10 15:00	15.6	52	↗ 8-12	750	значна хмарність
	20.10 09:00	4,6	86	↑ 4-6	753	мінлива хмарність
	19.10 21:00	3,6	56	↘ 2-5	753	ясно
Чорнобиль	20.10 15:00	14,8	51	↓ 4-11	752	значна хмарність
	20.10 09:00	2,9	70	↘ 1-4	756	значна хмарність
	19.10 15:00	10,9	39	↘ 3-7	757	Ясно
Фастів	20.10 15:00	13.9	56	6-12	747	значна хмарність
	20.10 09:00	3.2	92	↑ 2-5	750	значна хмарність
	19.10 21:00	2.7	59	↗ 1-3	751	ясно
Миронівка	20.10 15:00	14.1	56	↗ 6-10	753	значна хмарність
	20.10 09:00	3.4	60	↘ 2-4	756	мінлива хмарність
	19.10 21:00	4.2	63	→ 1-3	756	мінлива хмарність
Тетерів	20.10 15:00	15,4	52	↘ 1-5	752	значна хмарність
	20.10 09:00	6.0	76	↘ 1-4	756	значна хмарність
	19.10 21:00	-0,2	76	☀ 0-4	758	ясно

Продовження таблиці 1.6

Вишгород	20.10 15:00	14.4	55	↗ 5-9	755	значна хмарність
	20.10 09:00	4.8	65	↗ 3-5	759	мінлива хмарність
	19.10 21:00	6.6	49	↘ 2-5	760	ясно
Яготин	20.10 15:00	13,3	48	↘ 5-10	755	значна хмарність
	20.10 09:00	0.9	92	↗ 1-3	758	мінлива хмарність
	19.10 21:00	3.9	74	↘ 2-5	757	ясно

Також, за допомогою багатьох інтернет ресурсів, кожен має змогу порівняти температуру повітря за останні роки(таблиця 1.7). Мною був використаний електронний ресурс «Центральна Геофізична Обсерваторія імені Бориса Срезневського».

Таблиця 1.7 – Багаторічні значення добової температури повітря у Києві (за даними ЦГО)

Дата	Середня доба	Мінімальна	Максимальна
14 жовтня	9,2	-4,9 1992р.	25,7 1993р.
15 жовтня	9,0	-7,8 1898р.	24,1 2019р.
16 жовтня	8,8	-4,9 1976р.	23,4 2018р.
17 жовтня	8,5	-5,8 1976р.	24,0 2018р.
18 жовтня	8,5	-5,3 1976р.	23,1 2018р.
19 жовтня	8,1	-4,8 1882р.	23,3 2019р.
20 жовтня	7,6	-5,6 1920р.	20,9 1921р.

Крім цього, для аналізу МП, що передують даній події, можна оцінити стан додаткових МП, ґрунтуючись на даних з відкритих джерел, описаних вище.

1.2. Аналіз засобів і методів автоматизації короткострокового прогнозування

Залежно від розв'язуваних завдань, безліч програмного забезпечення, так чи інакше пов'язаного з обробкою і аналізом МД, можна класифікувати за типом вирішуваних завдань на монітори МП, утиліти для конвертації і читання запису МД, обробники МД (аналізатори, програми візуалізації) і власне програми для побудови прогнозів МП.

Розглянемо деякі безкоштовні програми аналізатори.

Delivery - програма аналізу, в тому числі і МД, на основі Бейсовського методу інверсії, що дозволяє здійснювати аналіз основних МП, за методикою оцінки кінематики поширення хвиль різної етимології.

Пакет обробки, аналізу і візуалізації (2-D і 3-D) геофізичних даних JRG. Прогноз побудований на аналізі сплесків МП з їх попередньою фільтрацією і ранжування. В основі аналізу лежить нейромрежевий метод пошуку головних компонентів з динамічним визначенням порогу вибірки.

Пакет моделювання та аналізу МП методом томографічної інверсії TEMIMAGE дозволяє змоделювати поширення ділянки аномальних відхилень МП. Аналіз отриманих даних здійснюється методом порівняння з даними ретроспективного періоду, за допомогою регресійного аналізу та знаходженням інтегральної залежності вибраних МП від досліджуваних МД.

Для аналізу (оцінка невизначеності, рівня змін, значення взаємозв'язку) геофізичних, в основному приповерхових даних на наявність аномалій можна використовувати програму WaveletExtractor, що здійснює підготовку вихідних даних методом вейвлет перетворення з подальшим порівнянням з еталонним методом спектрального аналізу.

Використання спектрального аналізу (зміна частоти дискретизації, перетворення Фур'є, згортання) з подальшою статистичною обробкою отриманих результатів (інтерполяція, злиття, тренд тощо) з використанням задалегідь

підготовлених даних можна виконати в проєкті METEO. Даний програмний продукт не здійснює підготовку даних і не виконує самого прогнозування МП.

Для виявлення головних компонент різних МД, отриманих від метеостанцій, в різних форматах, можна використовувати програму GeoSeis, виявлення відмінностей від ретроспективного періоду побудовано на нейронній мережі зворотного поширення.

Розглянемо інноваційні програмні продукти, що дозволяють виконувати прогнозування МП на основі методик, розглянутих в п.1.1. Під час 18 сесії Конференції Сторін Рамкової конвенції Організації Об'єднаних Націй про зміну клімату була розглянута нова модель веб-інструменту прогнозування. Експеримент з вивчення систем спостережень та питань передбачуваності (THORPEX) являє собою 10-річну міжнародну програму досліджень і розробок. Вона створена ВМО для прискорення покращення точності прогнозів погоди зі значними наслідками тривалістю від одного дня до двох тижнів. Портал TIGGE (Великий ансамблевий комплексний прогноз в рамках THORPEX) надає десять комплектів квазі-оперативних глобальних даних ансамблевих прогнозів з дводенною затримкою з жовтня 2006 року. Використання TIGGE є ефективним способом реагування на екстремальні погодні явища, такі, як періоди сильної спеки, повені, сильні зливи, урагани і атмосферні блокування. Екстремальні погодні явища, які можуть викликати загибель людей і катастрофічні збитки, як очікується, будуть зустрічатись частіше, поряд з глобальним потеплінням. Отже, точні передбачення екстремальних погодних явищ проводяться на благо суспільства, економіки та навколишнього середовища.

Глобальна інтерактивна система прогнозів – робоча група TIGGE - займається розробкою продукції на основі веб-інтерфейсу, яка орієнтована на користувача для тропічних циклонів і сильних опадів.

Ці продукти раннього попередження засновані на оперативних середньострокових ансамблевих прогнозах з чотирьох провідних світових центрів

прогнозу: Європейського центру середньострокових прогнозів погоди, Японського метеорологічного агентства, Метеобюро Сполученого Королівства та національних центрів з прогнозування стану навколишнього середовища у Сполучених Штатах Америки. Прогноз включає ймовірність виникнення екстремальних погодних явищ, таких як сильний дощ, сильний вітер, і вкрай високих/низьких температурах, заснований функції щільності кожної моделі. Багатоцентричний ансамблевий прогноз надає узагальнений малюнок виникнення ймовірностей одноцентричних ансамблевих прогнозів.

У США також існує мережа метеорадарів, яка включає понад 120 доплерівських радарів. Нещодавно вони були вдосконалені за допомогою технології Dual Polarization Technology, аналогічної до тієї, що застосували в ДМРЛ-С. На даний момент мережа погодних радарів у США вважається найрозвиненішою у світі. Радарами покрита практично вся територія, причому східна частина країни з великим запасом. Саме тому короткостроковий прогноз погоди у Вашингтоні та Нью-Йорку вважається одним із найточніших на планеті.

У «Яндекс.Погоді» використовується технологія Метеум, заснована на метеорологічних моделях та машинному навчанні. Побудована на базі Матрікснета та навчена на великих масивах даних, нейронна мережа MLP, після попереднього аналізу головних компонентів МД дозволяє підвищити точність прогнозу [13].

Згідно з проведеним аналізом, враховуючи розглянуті методики та моделі на основі яких вони реалізовані, враховуючи класифікацію програмного забезпечення, а також з урахуванням висновків, отриманих вище, можна побудувати узагальнений алгоритм прогнозування метеорологічних властивостей (рисунок 1.7).

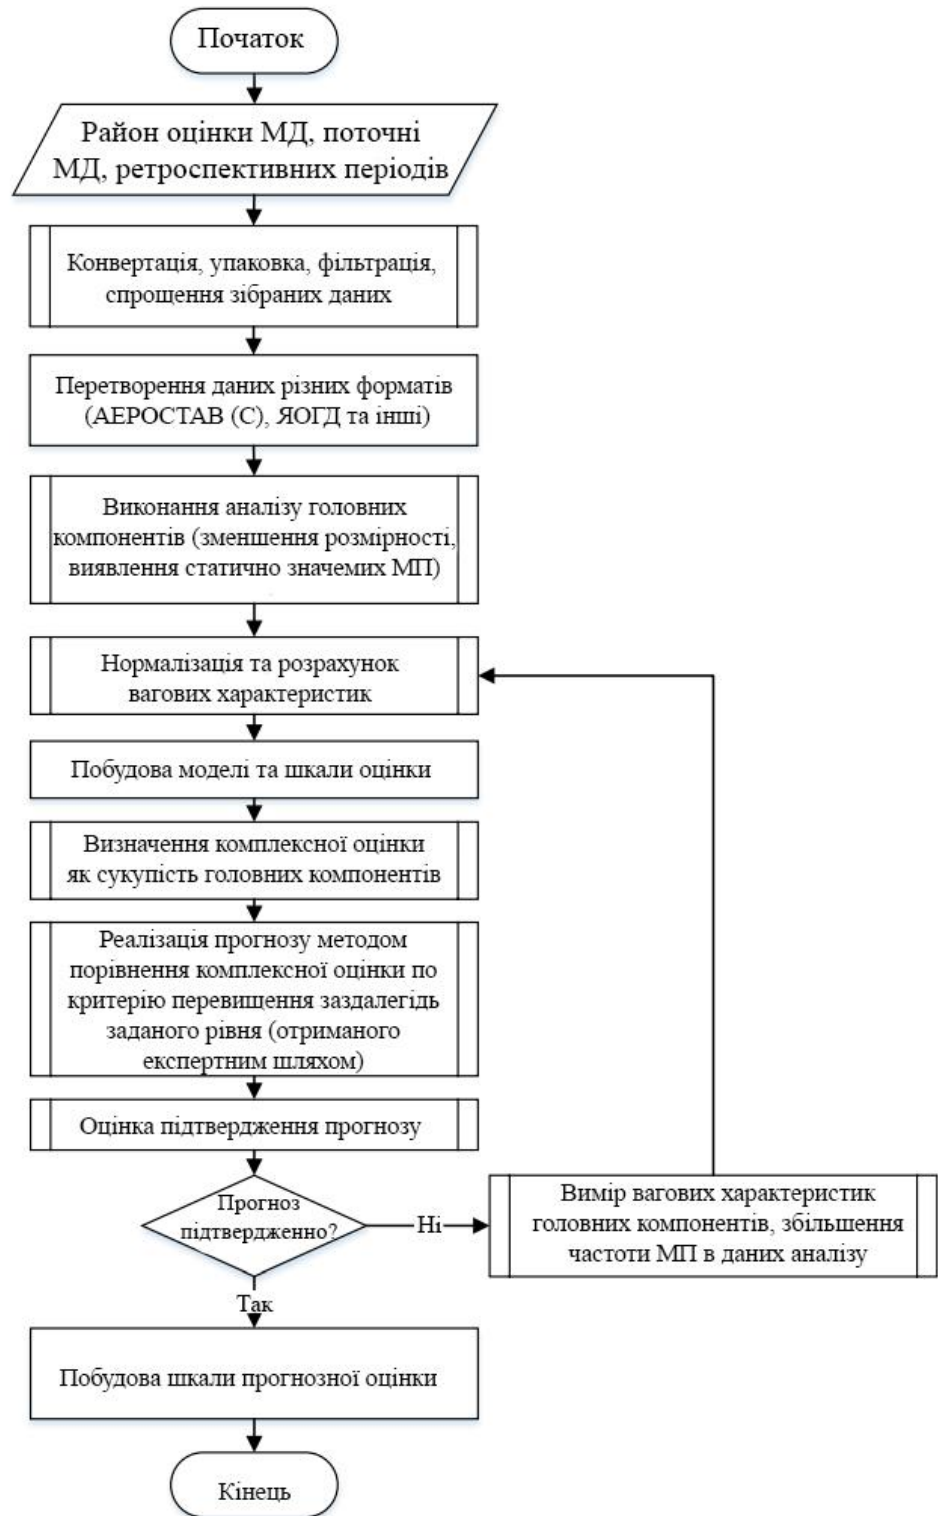


Рисунок 1.7 – Модель прогнозування метеорологічних параметрів

Аналіз програмного забезпечення, в частині прогнозування метеорологічних параметрів, на основі нейромережевого аналізу дозволяє зробити наступний висновок: всі розглянуті програми оперують даними від метеорологічних станцій (наземного, повітряного та космічного базування); всі розглянуті програми використовують певну модель оцінки, побудовану на відмінностях метеорологічних даних досліджуваних періодів від ретроспективних; всі розглянуті програми побудовано з використанням того чи іншого математичного апарату, що дозволяє реалізувати аналіз відмінностей порівнюваних періодів з використанням синтетичної градації терезів того чи іншого параметра або їх сукупності; у розглянутих програмах прогнозна оцінка будується методом порівняння розрахованої величини або комплексної оцінки можливої події, за критерієм перевищення експериментально встановленого порогу мул за допомогою однієї з розглянутих математичних прогностичних моделей.

Виходячи з цього, при реалізації програми прогнозування змін основних МП буде використаний алгоритм, показаний на рисунку 1.7.

1.3. Модель підготовки даних для прогнозування метеорологічних параметрів

Враховуючи проаналізовані статистичні моделі побудови прогнозу, використовувані ними методи, а також реалізований алгоритм (рисунку 1.7), розглянемо системи самоорганізації, засновані на принципі навчання Хебба [14] та опишемо метод аналізу головних компонент* (далі АК), який буде використовуватися для зменшення розмірності і отримання репрезентативної вибірки даних у статистичній системі обробки МД. Для того щоб мережа досягла самоорганізації, зворотний зв'язок між змінами в синаптичних вагах та змінами в активності сигналів має бути позитивним. Відповідно до цього можна сформулювати основні принципи самоорганізації.

ПРИНЦИП 1. Зміна синаптичних терезів веде до самопосилення мережі. Використовуваний попереднього аналізу провісників механізм насправді є підтвердженням постулату навчання Хебба.

ПРИНЦИП 2. Обмеженість ресурсів веде до конкуренції між синапсами і, таким чином, до вибору синапсів, що найбільш успішно розвиваються, за рахунок інших (тобто найбільш підхожих) [14].

ПРИНЦИП 3. Модифікація синаптичних терезів веде до кооперації. Присутність сильного синапсу може посилити та інші синапси у світлі загальної системи конкуренції у мережі.

ПРИНЦИП 4. Порядок і структура сигналів активації містять надмірну інформацію, що накопичується мережею у формі знань, що є необхідною умовою навчання, що самоорганізується.

Деяка частина знань може бути отримана за допомогою спостереження статистичними параметрами, такими як середнє значення, дисперсія і матриця кореляції вхідних даних.

Розглянуті принципи навчання, що самоорганізується, утворюють базис для реалізації адаптивних алгоритмів АК, а також для самоорганізованих карт Кохонена.

Метод АК інтенсивно використовується для скорочення розмірності опису, виділення значущої інформації, візуалізації даних та ін. Ще один варіант використання - це аналіз відповідностей, інші області застосування це техніка скорочення динамічних моделей яка інтенсивно застосовується в кліматології [64, 15].

З погляду завдання статистичного прогнозування МП практичне значення АК у тому, що він забезпечує ефективний спосіб скорочення розмірності [15]. Зокрема, можна скоротити кількість ознак, необхідних для ефективного представлення даних, або, скоротити дані одиночного датчика МП, наприклад, термометра, усуваючи ті лінійні комбінації, які мають малі дисперсії, і залишаючи ті, дисперсії яких великі. Нехай $\lambda_1, \lambda_2, \dots, \lambda_l$ - найбільші l власних значень матриці кореляції. Тоді вектор

даних x можна апроксимувати, відсікаючи члени розкладання (27) після l -го доданку:

$$\hat{x} = \sum_{j=1}^l a_j q_j = [q_1, q_2, \dots, q_n] \begin{bmatrix} a_1 \\ a_2 \\ a_n \end{bmatrix}, l \leq m. \quad (1.1)$$

Маючи вихідний вектор x , за допомогою виразу можна обчислити головні компоненти з (1.28) наступним чином:

$$\begin{bmatrix} a_1 \\ a_2 \\ a_n \end{bmatrix} = \begin{bmatrix} a_1^T \\ a_2^T \\ q_1^T \end{bmatrix} x, l \leq m. \quad (1.2)$$

Лінійна проєкція (1.2) з $\mathfrak{R}m$ в $\mathfrak{R}l$ (тобто відображення з простору даних до простору ознак) є методом кодування для наближеного представлення вектора даних x (рисунок 1.8, а). Відповідно лінійна проєкція з $\mathfrak{R}l$ в $\mathfrak{R}m$ (тобто зворотнє відображення простору ознак у простір даних) є методом декодування (див. рисунок 1.8, б).

Слід зазначити, що найбільш значущі власні значення $\lambda_1, \lambda_2, \dots, \lambda_l$ не беруть участь у обчисленнях (1.8) і (1.9), але необхідні визначення кількості АК, використовуваних для кодування і декодування.

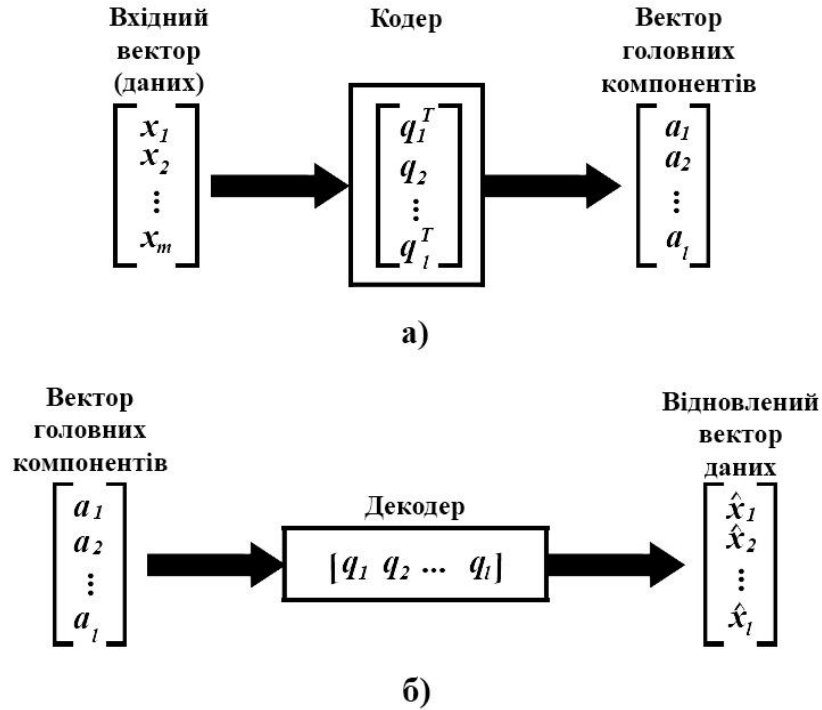


Рисунок 1.8 – Два етапи АК: кодування (а) та декодування (б)

Вектор помилки апроксимації e дорівнює різниці між вектором вихідних даних x та вектором наближених даних \hat{x} (рисунок 1.8):

$$e = x - \hat{x}. \quad (1.3)$$

Підставляючи (1.27) та (1.28) до (1.30), отримаємо:

$$e = \sum_{i=l+1}^m a_i q_i. \quad (1.4)$$

Вектор помилки e є ортогональним вектором наближених даних x (рисунок 1.8). Іншими словами, скалярний добуток векторів e і \hat{x} дорівнює нулю. Використовуючи (1.1) і (1.4), цю властивість можна довести:

$$e^T \hat{x} = \sum_{i=l+1}^m a_i q_i q_i^T \sum_{j=1}^l a_j q_j = \sum_{i=l+1}^m a_i \sum_{j=1}^l a_j q_i^T q_j = 0, \quad (1.5)$$

де враховується друга умова вираження. Співвідношення (1.5) називають принципом ортогональності.




Рисунок 1.9 – Взаємозв'язок вектора x , його реконструйованої версії \hat{x} та вектора помилки e

Загальна дисперсія m компонентів вектора даних x складає:

$$\sum_{j=1}^m \sigma_j^2 = \sum_{j=1}^m \lambda_j, \quad (1.6)$$

де σ_j^2 - дисперсія j -го головного компонента α_j . Загальна дисперсія l елементів наближеного вектора \hat{x} дорівнює:

$$\sum_{j=1}^l \sigma_j^2 = \sum_{j=1}^l \lambda_j. \quad (1.7)$$

Таким чином, загальна дисперсія $(l - m)$ елементів вектора помилки апроксимації $x - \hat{x}$ дорівнює:

$$\sum_{j=l+1}^m \sigma_j^2 = \sum_{j=l+1}^m \lambda_j. \quad (1.8)$$

Числа $\lambda_{l+1}, \dots, \lambda_m$ є найменшими $(m - l)$ власними значеннями матриці кореляції R . Вони відповідають доданкам, виключеним із розкладання (1.1), що використовується для побудови наближеного вектора \hat{x} . Чим ближчі ці власні значення до нуля, тим ефективнішим буде скорочення розмірності (як результат застосування АК вектора даних) у поданні інформації вихідних даних. Таким чином, для того щоб забезпечити скорочення розмірності вхідних даних, потрібно обчислити власні значення і власні вектори матриці кореляції векторів вхідних даних, а потім проектувати ці дані на підпростір, що задається власними векторами, ортогонально, відповідними домінуючим власним значенням цієї матриці. Цей

спосіб представлення даних зазвичай називають просторової декомпозицією. Аналіз МД проводиться з багатовимірними множинами даних, у яких кластерна структура даних прихована, саме тому необхідно виконувати статистичний аналіз, аналогічний до описаного вище аналізу основних компонентів.

Висновок до 1 розділу

Аналіз програмного забезпечення, в частині прогнозування метеорологічних параметрів, на основі нейромережевого аналізу дозволяє зробити наступний висновок: всі розглянуті програми оперують даними від метеорологічних станцій (наземного, повітряного та космічного базування); всі розглянуті програми використовують певну модель оцінки, побудовану на відмінностях метеорологічних даних досліджуваних періодів від ретроспективних; всі розглянуті програми побудовано з використанням того чи іншого математичного апарату, що дозволяє реалізувати аналіз відмінностей порівнюваних періодів з використанням синтетичної градації терезів того чи іншого параметра або їх сукупності; у розглянутих програмах прогнозна оцінка будується методом порівняння розрахованої величини або комплексної оцінки можливої події, за критерієм перевищення експериментально встановленого порогу мул за допомогою однієї з розглянутих математичних прогностичних моделей.

РОЗДІЛ 2

АНАЛІЗ АЛГОРИТМІВ ТА КОМП'ЮТЕРНЕ МОДЕЛЮВАННЯ

2.1. Обробка багатовимірною сигналу фільтром Хебба

Існує тісний взаємозв'язок між поведінкою нейронних мереж, що самоорганізуються, і статистичним методом АК. Один лінійний нейрон з Хеббовським правилом адаптації синаптичних ваг може бути перетворений на фільтр виділення першого головного компонента вхідного розподілу [16].

Розглянемо нейронну модель, вихід якої є лінійною комбінацією вхідних векторів, показану на рисунку 2.1а. Нейрон отримує безліч з m вхідних сигналів x_1, x_2, \dots, x_m через відповідну множину m синапсів w_1, w_2, \dots, w_m . Вихід отриманої моделі можна визначити, як

$$y = \sum_{i=1}^m w_i x_i \quad (2.1)$$

Згідно з постулатом Хебба, синаптична вага w_i змінюється в часі, сильно зростаючи, якщо передсинаптичний сигнал x_i та постсинаптичний сигнал y збігаються один з одним.

Загальна робота нейрона представляється як комбінація двох граф передачі сигналу, показаних на рисунку 2.3. Граф на рисунку 2.3, а відображає залежність виходу $y(n)$ від синаптичних ваг $w_1(n), w_2(n), \dots, w_m(n)$, згідно (2.1). Графи передачі сигналу на рисунку 2.1 б ілюструють вирази (2.1) і (2.2). Передатна функція z^{-1} у середній частині графа є оператором одиничної затримки. Вихідний сигнал $y(n)$ на рисунку 2.1, а виступає у ролі передавальної функції на рисунку 2.1 б. Граф на рисунку 2.1 б ясно показує наступні дві форми внутрішнього зворотного зв'язку, що діє в нейроні:

- позитивний зворотний зв'язок для самопосилення і зростання синаптичних ваг $w_i(n)$ відповідно до зовнішнього вхідного сигналу $x_i(n)$;
- негативний зворотний зв'язок $-y(n)$ для контролю зростання зв'язків, що стабілізує синаптичну вагу $w_i(n)$.

$(-y(n)w_i(n))$ пов'язано з фактором забування, який часто використовується у правилах навчання, але з однією відмінністю: фактор забування стає більш явно вираженим із посиленням вихідного сигналу $y(n)$. Такий тип управління має чітке нейробіологічне пояснення [16].

Наведемо матричне формулювання алгоритму. Введемо такі позначення:

$$x(n) = [x_1(n), x_2(n), \dots, x_m(n)]^T \quad (2.2)$$

та

$$w(n) = [w_1(n), w_2(n), \dots, w_m(n)]^T. \quad (2.3)$$

Вхідний вектор $x(n)$ та вектор синаптичних ваг $w(n)$ зазвичай є реалізаціями випадкових векторів. Використовуючи це векторне уявлення, вираз (2.1) можна переписати у формі скалярного твору:

$$y(n) = x^T(n)w(n) = w^T(n)x(n) \quad (2.4)$$

Аналогічно, вираз (2.3) можна переписати у такому вигляді:

$$w(n+1) = w(n) + \eta y(n)[x(n) - y(n)w(n)]. \quad (2.5)$$

Підставляючи (2.4) (2.5), отримуємо:

$$w(n+1) = w(n) + \eta [x(n)x^T(n)w(n) - w^T(n)x(n)x^T(n)w(n)w(n)] \quad (2.6)$$

Алгоритм навчання (2.6) є нелінійним стохастичним. різницеве рівняння (алгоритм навчання, що самоорганізується), яке дозволяє провести аналіз збіжності на основі загальних методів аналізу збіжності стохастичних алгоритмів апроксимації. Рівняння (2.7) будучи окремим випадком алгоритму стохастичної апроксимації:

$$w(n+1) = w(n) + \eta(n)h(w(n), x(n)), \quad n = 1, 2, \dots \quad (2.7)$$

де $\eta(n)$ складається з позитивних скалярних величин, а $h(\cdot, \cdot)$ є детермінованою функцією з деякою умовою регулярності. Дана функція визначає повну структуру алгоритму матричної форми. У [24] наведено різні підходи до аналізу збіжності, що приводять це завдання до задачі збіжності диференціальних рівнянь (ODE).

За допомогою аналізу стійкості ODE можна досліджувати збіжність рекурсивного алгоритму (2.7), що визначає фільтр для отримання максимального значення.

З (2.7) видно, що функцію корекції $h(w, x)$ визначено наступним чином:

$$h(w, x) = x(n)y(n) - y^2(n)w(n) = x(n)x^T(n)w(n) - [w^T(n)x(n)x^T(n)w(n)]w(n). \quad (2.8)$$

Розглянемо приклад узгодженого фільтра, необхідного для попередньої обробки векторів містять МД, де випадковий вектор $X(n)$, складений як: $X(n) = s + V(n)$, де s - фіксований одиничний вектор, що представляє компонент корисного сигналу під час аналізу МП; $V(n)$ - компонент шуму із середнім значенням 0. Матриця кореляції такого вхідного вектора має такий вигляд: $R = E[X(n)X^T(n)] = ss^T + \sigma^2 I$ - дисперсія елементів вектора шуму $V(n)$; I - одинична матриця. Найбільше власне значення такої матриці буде наступним: $\lambda_1 = 1 + \sigma^2$.

Відповідний власний вектор q_1 має вигляд $q_1 = s$.

Нескладно показати, що це рішення задовольняє рівнянню для власних значень: $Rq_1 = \lambda q_1$.

Для описаної в даному прикладі ситуації самоорганізується лінійний нейрон (при його збіжності до сталого стану) виступає в як узгоджений фільтр, його імпульсний відгук (представлений синаптичними вагами) відповідає компоненту корисного сигналу s Вхідний вектор $X(n)$.

Для евристичного розуміння того, як узагальнений алгоритм Хебба працює насправді, в першу чергу запишемо версію алгоритму матричному поданні:

$$\Delta w_{ji}(n) = \eta y_j(n) x'_i(n) - \eta y_j^2(n) w_{ji}(n), \quad j = 1, 2, \dots, l, \quad (2.9)$$

де

$$x'(n) = x(n) - \sum_{k=1}^{j-1} w_k(n) y_k(n). \quad (2.10)$$

Вектор $x'(n)$ являє собою модифіковану форму вхідного вектор. Грунтуючись на уявленні (2.9), можна зробити такі спостереження.




Рисунок 2.1 — Подання узагальненого алгоритму Хебба як графа передачі сигналу: граф рівняння (2.6) (а); граф виразів (2.7) (б)

Для першого нейрона мережі прямого поширення: $j = 1: x'(n) = x(n)$. Для цього випадку узагальнений алгоритм Хебба зводиться до вигляду (2.11), записаному для одиночного нейрона. Вище показано, що цей нейрон отримує перший основний компонент вхідного вектора $x(n)$.

Для другого нейрона мережі на рисунку 2.3 можна записати: $jj = 2: x'(n) = x(n) - w_1(n)y_1(n)$.

Для третього нейрона можна записати:
 $j = 3: x'(n) = x(n) - w_1(n)y_1(n) - w_2(n)y_2(n)$

Продовжуючи цю процедуру для нейронів мережі прямого, що залишилися. поширення, отримуємо, що кожен із виходів мережі, навчений за допомогою узагальненого алгоритму Хебба, є відгук на конкретний власний вектор матриці вхідного кореляції вектора, причому окремі виходи впорядковані за спаданням її власних значень.

Цей метод обчислення власних векторів аналогічний методу, який отримав назву процесу вичерпання. Він використовує процедуру, аналогічну ортогоналізації Грама-Шмідта.

2.2. Обчислювальний алгоритм попередньої підготовки даних

Обчислення, що виконуються розглянутим алгоритмом, можна записати в наступному вигляді:

Обчислення, що виконуються узагальненим алгоритмом Хебба, є простими, і їх можна описати наступною послідовністю дій.

У момент часу $n = 1$ ініціалізуємо синаптичні ваги w_{ji} мережі випадковими малими значеннями. Призначаємо параметр швидкості навчання η деяке мале позитивне значення.

Для $n = 1, j = 1, 2, \dots, l$ та $i = 1, 2, \dots, m$ обчислимо:

$$y_j(n) = \sum_{i=1}^m w_{ji}(n)x_i(n)$$

$$\Delta w_{ji}(n) = \eta[y_j(n)x_i(n) - y_j(n) \sum_{k=1}^j w_{ji}(n)y_k(n)],$$

де $x_j(n)$ - i -й компонент вхідного вектора $x(n)$ розмірності $m \times 1$; l - необхідне число основних компонентів.

Збільшуємо значення n на одиницю, переходимо до кроку 2 і продовжуємо до тих пір, поки синаптичні ваги w_{ji} не досягнуть своїх встановлених значень. Для великих n синаптичні ваги w_{ji} нейрона j сходяться до i -му компоненту власного

вектора, пов'язаного з j -м власним значенням матриці кореляції вхідного вектора $x(n)$.

У [3] вказується на значущість безлічі алгоритмів, запропонованих у [8] для АК (тобто для алгоритмів Хебба, розглянутих вище), в алгоритмі ієрархічної кластеризації. Вони просувають гіпотезу у тому, що ієрархічна кластеризація може виступати як фундаментальний властивості (принаймні частково) пам'яті, яку можна використовувати для розпізнавання властивостей довкілля. Звідси випливає, що самоорганізований аналіз головних компонентів може відігравати суттєву роль ієрархічної кластеризації навчальних областей не через його властивостей оптимальності відновлення, а завдяки його вбудованій властивості створювати проєкції кластерів із добрим поділом.

Розглянутий алгоритм АК буде використаний у розв'язанні задачі квантування вектора навчання (відновлення, попередньої підготовки та стиснення МД), отриманих з різних джерел, що представляють безліч МП.

2.3. Самоорганізовані системи та навчання мережі

Архітектура систем, що самоорганізуються, може приймати безліч абсолютно різних форм. Наприклад, така мережа може складатися з вхідного та вихідного шару, пов'язаних прямими зв'язками, і включати непрямі зв'язки між нейронами другого шару. Ще одним прикладом можуть бути багатошарові мережі прямого поширення, в яких самоорганізація проявляється при переході від одного шару до іншого. В обох випадках процес навчання полягає в зміні синаптичних ваг всіх зв'язків у системі, що періодично повторюється, у системі у відповідь на подачу вхідних сигналів відповідно до приписаних правил до отримання кінцевої конфігурації системи[27].

Важливою властивістю нейронних мереж є їхня здатність навчатися на основі прикладів з навколишнього середовища та за допомогою цього навчання підвищувати продуктивність роботи. Метою навчання є побудова бажаного відображення вхідного сигналу у вихідний, яке мережа має апроксимувати. Метою алгоритмів навчання, що самоорганізуються, є виявлення у безлічі вхідних даних

суттєвих образів або ознак, причому цей процес відбувається без участі вчителя. Для цього алгоритм реалізує безліч правил локальної природи, що дозволяє навчатися обчислення відображення вхідного сигналу на вихідний з необхідними властивостями. Тут термін "локальний" має на увазі наступне. Зміни синаптичних ваг нейрона визначаються лише безпосередніми сусідами цього нейрона. Моделі мереж, які навчаються на основі принципу самоорганізації, значно більшою мірою відображають властивості природних явищ, ніж архітектури, які навчаються з учителем [28], [29].

Як було зазначено, для навчання необхідна надмірність вхідних даних, що яскраво виявляється у наявності великої кількості МП. Вище був описаний алгоритм, що дозволяє здійснити отримання статистично значних даних на етапі підготовки. Опишемо власне аналіз даних властивих нейронної мережі, що самонавчається. Як модель аналізу даних розглянемо алгоритм векторного кодування – модель Кохонена [3]. Ця модель реалізує топологічне відображення (рисунок 2.2), яке оптимально розміщує фіксовану кількість векторів (тобто кодових слів) у вхідний простір вищої розмірності і, таким чином, полегшує аналіз даних.

Виходячи з цього, модель Кохонена можна уявити як підхід векторного квантування, що включає кодування та декодування. Цей підхід ґрунтується на положеннях теорії комунікацій [73], [74].




Рисунок 2.2 – Картка ознак, що самоорганізується в моделі Кохонена

Основною метою карт самоорганізації, в моделі, що розглядається, є перетворення векторів сигналів, що надходять довільну розмірність, одно- або двомірну дискретну карту. При цьому таке перетворення здійснюється адаптивно, в топологічно упорядкованій формі. На рисунку 2.3 показана схематична діаграма двовимірної решітки нейронів, що використовується як дискретна карта.




Рисунок 2.3 – Двовимірні грати нейронів, що використовуються як дискретна карта

Усі нейрони цих грат пов'язані з усіма вузлами вхідного шару. Ця мережа має структуру прямого поширення з одним обчислювальним шаром, що складається з нейронів, упорядкованих у стовпці та рядки.

Алгоритм, відповідальний за формування карток, що самоорганізуються, починається з ініціалізації синаптичних вагів мережі. Зазвичай це відбувається за допомогою призначення синаптичних ваг малих значень, сформованих генератором випадкових чисел. При такому формуванні карта ознак спочатку немає будь-якого порядку ознак. Після коректної ініціалізації мережі для формування карти самоорганізації запускаються три наступних основних процесів.

1. Конкуренція.

Для кожного вхідного образу нейрони мережі обчислюють відносні значення дискримінантної функції. Ця функція є основою конкуренції серед нейронів.

2. Кооперація.

Нейрон, що переміг, визначає просторове положення топологічної околиці нейронів, забезпечуючи тим самим базис для кооперації між цими нейронами.

3. Синаптична адаптація.

Останній механізм дозволяє збудженим нейронам збільшувати власні значення дискримінантних функцій стосовно вхідних образів за допомогою відповідних коригувань синаптичних ваг. Коригування здійснюються таким чином, щоб відгук нейрона-переможця на подальше застосування аналогічних прикладів посилювався.

Процеси конкуренції та кооперації здійснюються відповідно до двох із чотирьох принципів самоорганізації, описаних вище. Що ж до принципу самопосилення, він реалізується в модифікованій формі - формі навчання Хебба для адаптивного процесу.

Опишемо процеси властиві формуванню карток, що самоорганізуються.

1. Процес конкуренції.

Вибираючи нейрон із найбільшим скалярним твором $w_j^T x$, ми в результаті визначаємо місце розташування, яке має стати центром топологічної околиці збудженого нейрона

2. Процес кооперації.

Нейрон-переможець знаходиться у центрі топологічної околиці співпрацюючих нейронів. Основним питанням є механізм визначення коректного топологічного околиці. Відповідно до принципів латеральної взаємодії, збуджений нейрон завжди намагається порушити найбільш близькі (у просторі) до нього нейрони, що і призводить до визначення топологічної околиці нейрона, що переміг j , яка зменшується (втрачає інтенсивність) із збільшенням відстані, правило Конкурентне навчання розглянуто в роботі Гроссберга [16] та роботах [24], [20].

3. Процес адаптації

Для того, щоб мережа могла самоорганізуватися, вектор синаптичних ваг w_j нейрона j повинен змінюватися відповідно до вхідного вектора x . У постулаті навчання Хебба синаптична вага посилювалася при одночасному виникненні передсинаптичної та постсинаптичної активності, що добре підходить до асоціативного навчання і не підходить для навчання без вчителя. Для подолання цієї проблеми введемо додаткове доданок забування $g(y_j)w_j$, де w_j - вектор синаптичних ваг нейрона j ; $g(y_j)$ - деяка позитивна скалярна функція відгуку y_j . Єдиною вимогою, що накладається на функцію $g(y_j)$, є рівність нулю постійного доданку до ряду Тейлора функції $g(y_j)$, що, у свою чергу, тягне виконання співвідношення

$$g(y_j) = 0 \text{ при } y_j = 0. \quad (2.11)$$

Декомпозиція процесу адаптації синаптичних вагів мережі, що обчислюється згідно (2.17), дозволяє отримати два етапи – етап самоорганізації та етап збіжності.

1. Етап самоорганізації та упорядкування.

На цьому етапі відбувається топологічне впорядкування векторів ваг. У аналізованому роботі алгоритмі даний етап є витратним, його виконання може вимагати до 10000 ітерацій, тому особливу увагу необхідно приділити попередньої підготовки даних провісників, вибору параметра швидкості навчання і ширини функції околиці.

Параметр швидкості навчання, за результатами експериментів, виявляється в межах $0,01 \leq \eta(n) \leq 0,12$ (з урахуванням його спадання) для цього у виразі константи η_0 і τ_2 дорівнюють 0,12 і 1000, відповідно.

2. Етап збіжності.

Другий етап адаптивного процесу необхідний для такого налаштування карти ознак, яка дозволяє отримати найбільш точне квантування вхідного простору. Кількість ітерацій даного етапу, достатня для етапу збіжності, приблизно в 500 разів

перевищує кількість нейронів мережі. Таким чином, кількість ітерацій етапу збіжності може досягати тисяч і десятків тисяч і є найбільш витратною за часом.

2.4. Опис алгоритму виявлення значимих метеорологічних параметрів

Сутність алгоритму SOM[30], запропонованого Кохоненом, полягає у простому геометричному обчисленні властивостей Хеббоподібного правила навчання та латеральних взаємодій. Істотними характеристиками цього алгоритму є наступні:

- безперервний вхідний простір образів активації, що генеруються відповідно до деякого розподілу ймовірності;
- топологія мережі у формі ґрат, що складається з нейронів. Вона визначає дискретний вихідний простір;
- функція околиці $h_{j,i}(n)$, яка визначена в околиці нейрона-переможця $i(x)$;
- параметр швидкості навчання $\eta(n)$, для якого задається початкове значення η_0 і який поступово зменшується в часі n , але ніколи не досягає нуля.

Для функції околиці та параметра швидкості навчання на етапі впорядкування (тобто приблизно для першої тисячі ітерацій) можна використовувати формулу (2.11). Для гарної статистичної точності на етапі збіжності параметр $\eta(n)$ має бути встановлений у дуже мале значення (0,01 або менше). Що ж до функції околиці, то на початку етапу збіжності вона повинна містити лише найближчих сусідів нейрона-переможця (при цьому може включати лише його самого).

Крім ініціалізації, алгоритм проходить три основні кроки: підвибірка, пошук максимальної відповідності та коригування. Коротко весь алгоритм можна описати в такий спосіб.

1. Ініціалізація.
2. Підвибірка.
3. Пошук максимальної подоби.
4. Корекція.

5. Продовження.

Після завершення процесу збіжності алгоритму SOM обчислена ним карта ознак відображає важливі статистичні характеристики вхідного простору.

Карта ознак Φ має такі важливі властивості.

1. Властивість 1. Апроксимація вхідного простору.

Карта ознак Φ , представлена безліччю векторів синаптичних ваг $\{w_j\}$, у вихідному просторі A реалізує гарну апроксимацію вхідного простору X .

2. Властивість 2. Топологічний порядок.

Карта ознак Φ отримана використанням алгоритмом, є топологічно упорядкованою в тому сенсі, що просторове становище нейронів у ґратах відповідає конкретній місцевості з урахуванням відповідності ознак зміни МП вхідних МД.

3. Властивість 3. Відповідність густини.

Карта ознак Φ відбиває варіації у статистиках розподілу вхідного сигналу Області у вхідному просторі X , з якого беруться вектори x з більшою ймовірністю, відображаються в набагато більші області вихідного простору A і, таким чином Таким чином, з більшою роздільною здатністю, ніж області у вихідному просторі X , яких беруться вектори з меншою ймовірністю.

4. Властивість 4. Вибір ознак.

Для даних з вхідного простору з нелінійним розподілом картка, що самоорганізується, для апроксимації досліджуваного розподілу здатна отримати набір найкращих ознак.

Ця властивість є природним узагальненням властивостей 1-3. Ця властивість найбільш яскраво виражається при використанні АК на попередньому етапі підготовки даних.

2.5. Комп'ютерне моделювання та аналіз нейронної мережі

Для досліджування використовувалася мережа, що складається з 100 нейронів, упорядкованих у формі двовимірних ґрат розміром 10x10. Ця мережа навчається на двовимірних вхідних векторах x , елементи x_1 та x_2 які рівномірно розподілені в

областях $\{(-1 < x_1 < +1); (-1 < x_2 < +1)\}$. Для ініціалізації мережі синаптичні ваги вибираються випадковим чином[29].

На рисунку 2.4 показано три етапи навчання мережі подання вхідного розподілу. На рисунку 2.4, *а* показано рівномірний розподіл даних, використаних для навчання карти ознак. На рисунку 2.4, *б* показані вихідні значення випадково обраних синаптичних ваг.

На рисунку 2.4, *в, г* показані значення векторів синаптичних ваг після завершення етапів упорядкування і збіжності. Синаптичні ваги цих малюнків показані точками. Лінії показані на рисунку 2.4, з'єднують сусідні нейрони (вздовж рядків та стовпців) мережі.

Результати демонструють етапи впорядкування та збіжності, які характеризують процес навчання за алгоритмом SOM. Під час етапу упорядкування картка нагадує форму сітки (див. рисунок 2.4, *в*). До кінця цього етапу нейрони відображаються у правильному порядку. Під час етапу збіжності сітка намагається накрити весь вхідний простір. Наприкінці другого етапу (див. рисунок 2.4 *г*) статистичний розподіл нейронів на карті наближається до розподілу вхідних векторів (за винятком деяких граничних ефектів).

Порівнюючи кінцевий стан карти ознак (див. рисунок 2.4, *г*) з рівномірним розподілом вхідних сигналів (див. рисунок 2.4, *а*), ми бачимо, що точне налаштування карти, виконане на етапі збіжності, виявило окремі локальні нерівномірності, що є у вхідному розподілі.

Властивість топологічного упорядкування алгоритму SOM добре продемонстровано на рисунку 2.4, *г*. Зокрема, видно, що алгоритм (після збіжності) витяг топологію розподілу вхідного сигналу. У результатах комп'ютерного моделювання (див. рисунок 2.4) як вхідний простір X , так і вихідний простір A було двовимірним.

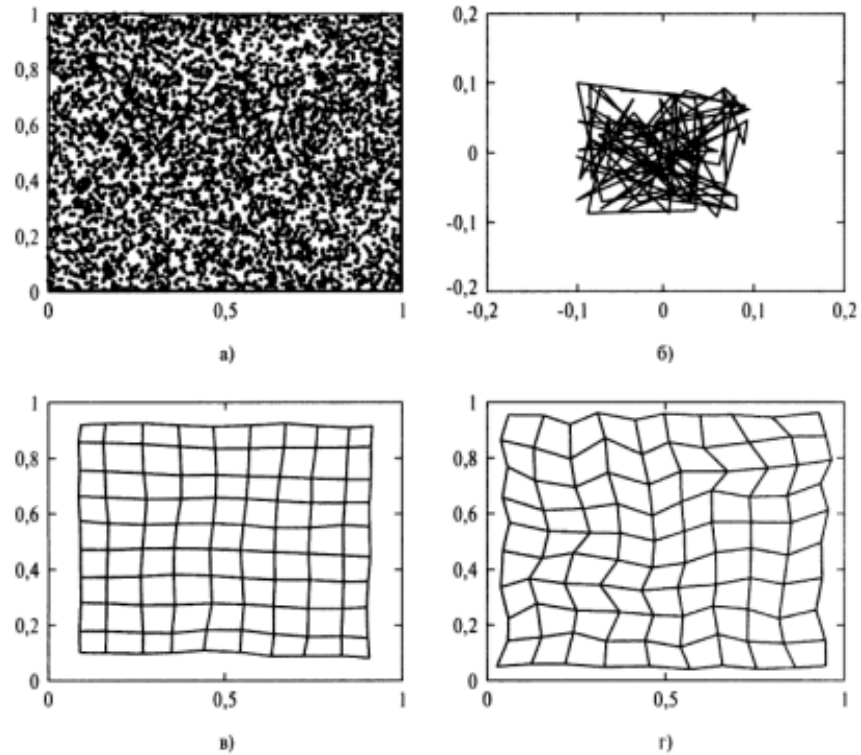


Рисунок 2.4 – розподіл вхідних даних (а); початковий стан двовимірних ґрат (б); стан ґрат в кінці етапу впорядкування (в); стан ґрат в кінці етапу збіжності (г)

Розглянемо випадок, коли розмірність вхідного простору X більша за розмірність вихідного простору A . Незважаючи на цю розбіжність, карта ознак Φ часто здатна сформувати топологічне уявлення вхідного розподілу. На рисунку 2.5 показано три етапи еволюції карти ознак, ініціалізованої на рисунку 2.5б і навчається на вхідних даних, взятих з рівномірного розподілу всередині квадрата (див. рисунок 2.4, а). Обчислення здійснювалися на одновимірних ґратах, що складається з 100 нейронів.




Рисунок 2.5 – розподіл вхідних даних (а); початковий стан двовимірної ґрати (б); стан ґрат в кінці етапу впорядкування (в); стан ґрат у кінці етапу збіжності (г)

На рисунку 2.5, в, г показані карти ознак після завершення етапів упорядкування і збіжності відповідно. На цих малюнках видно, що карта ознак, обчислена алгоритмом, неспроможна коректно уявити рівномірне заповнення квадрата досить щільно і досить хорошу апроксимацію двовимірного вхідного простору X . Операція, проведена в цьому експерименті та представлена картою ознак на рисунку 2.5 (де вхідний простір X представлений його проекцією на простір більш низької розмірності A), можна охарактеризувати як зниження розмірності.

На рисунку 2.6 представлені деталі динаміки функції околиці $h_{j,i}(n)$ та параметра швидкості навчання $\eta(n)$ з часом (тобто з кількістю епох) при ретроспективному моделюванні відображення сигналу (метеорологічного параметра) на одновимірну решітку.

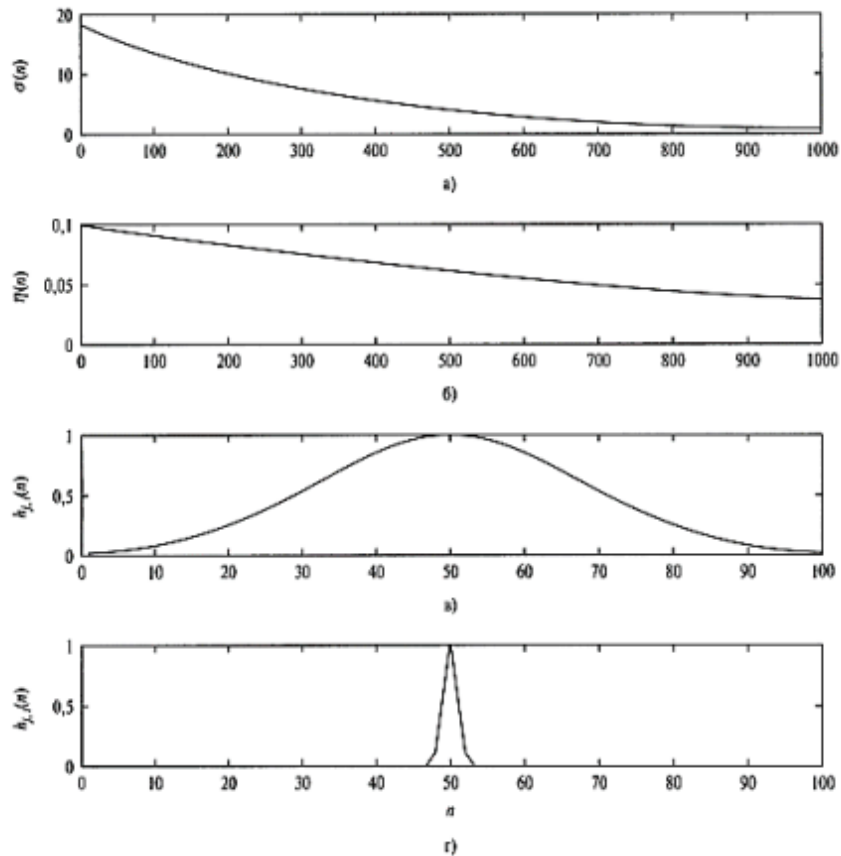


Рисунок 2.6 – Експоненційне зменшення параметра $\sigma(n)$ функції околиці (а); експоненційне зменшення параметра $\eta(n)$ (б); початкова форма гаусової функції околиці (в); форма функції околиці після завершення фази упорядкування (тобто на початку етапу збіжності) (г)

Параметр функції околиці $\sigma(n)$, показаний на рисунку 2.6, а, починає роботу з вихідного стану $\sigma_0 = 18$ і зменшується практично до одиниці за 1000 ітерацій етапу упорядкування.

Протягом цього етапу параметр швидкості навчання $\eta(n)$ починає роботу зі значення 0,1 і зменшується до значення 0,037. На рисунку 2.7, в показано початковий гауссовий розподіл нейронів навколо переможного нейрона, розташованого в центрі одновимірної решітки. На рисунку 2.6, г показана форма функції околиці в кінці етапу упорядкування. Під час етапу збіжності (5000 ітерацій) параметр швидкості

навчання поступово зменшувався від 0,037 до 0,001. Протягом цього етапу функція околиці скоротилася майже нуля.

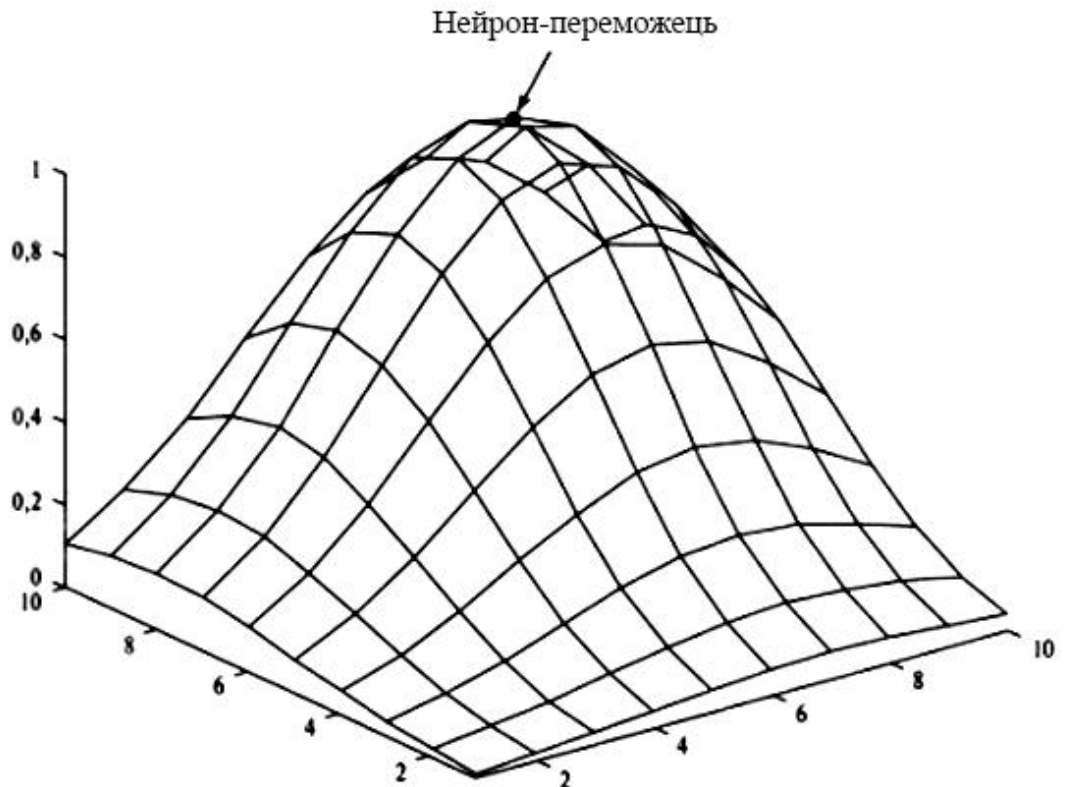


Рисунок 2.7 – Початкова умова для двовимірної гаусової функції околиці з центром у нейроні-переможці, розташованому в точці (7; 8) двовимірної решітки розміром 10x10 нейронів

Специфікації етапів упорядкування та збіжності при комп'ютерному моделюванні ретроспективного сигналу МД для випадку двовимірної решітки (див. рисунок 2.4) аналогічні використані для одномірної, за винятком того факту, що функція околиці тепер також стала двовимірною. Параметр $\sigma(n)$ розпочав роботу зі значення $\sigma_0 = 3$, за 1000 ітерацій зменшившись до 0,75. На рисунку 2.7 показано початковий стан гаусової функції околиці $h_{j,i}(n)$ для $\sigma_0 = 3$ і нейрона, що переміг, центрованого в точці (7; 8) двовимірної решітки розміром 10 x 10 нейронів.

2.6. Алгоритм квантування вектору навчання

Векторне квантування є прийомом використання структури вхідних векторів для стиснення даних. Зокрема, вхідний простір поділяється на безліч відокремлюваних (за ознаками) областей, кожній з яких визначається вектор відтворення. Коли для пристрїя квантування представляється новий вхідний вектор, в першу чергу визначається область, до якої належить даний вектор, а після цього створюється уявлення через вектор відтворення даної галузі. Таким чином, використовуючи некодовану версію вектора, що відновлюється. для зберігання або передачі вихідного вектора, можна досягти значної економії простору зберігання чи потужності каналу передачі за рахунок привнесення деяких спотворень. Безліч можливих векторів відтворення називаються книгою кодування пристрою квантування, яке окремі члени - кодовими словами.

Пристрїй векторного квантування, що має мінімальне спотворення при кодуванні, називається квантувачем Вороного, або квантувачем на основі найближчого сусїда, а осередками Вороного називають безліч точок у вхідному просторі, які відповідають підрозділу цього простору відповідно до правила найближчого сусїда, заснованого на Евклідовій метрі . На рисунку 2.13 показаний приклад вхідного простору, розділеного на чотири осередки Вороного з відповідними векторами відтворення (або векторами Вороного). Кожен із цих осередків містить ті точки вхідного простору, які розташовані найближче до вектора Вороного.




Рисунок 2.8 – Діаграма Вороного, що містить 4 осередки

Алгоритм SOM забезпечує наближений метод обчислення векторів Вороного без учителя. При цьому апроксимація визначається векторами синаптичні ваги нейронів на карті ознак. Це практично повторює опис властивості 1 алгоритму SOM, про який йшлося у розділі 2.1. Розрахунок карти ознак, таким чином, можна розглядати як перший з двох етапів адаптивного розв'язання задачі класифікації (рисунок 2.9). На другому етапі як механізм точного підстроювання карти ознак проводиться квантування вектор навчання.



Рисунок 2.9 – Блокова діаграма адаптивної класифікації множин, яка використовує карту ознак, що самоорганізується, і квантування вектору навчання

Квантування вектору навчання - це прийом навчання з учителем, який використовує інформацію про клас для невеликого зміщення Вороного вектора i , таким чином, для покращення якості областей рішень класифікатора. Вхідний вектор x випадково вибирається із вхідного простору. Якщо мітки класу вхідного вектора x та вектора Вороного w узгоджуються, останній зміщується у напрямку першого. Якщо ж мітки класів цих векторів не узгоджуються, вектор Вороного w зміщується у бік, протилежний вхідному вектору x .

Нехай $\{w_j\}_{j=1}^L$ - безліч векторів Вороного, а $\{x_i\}_{i=1}^N$ безліч вхідних векторів (спостережень). Передбачається, що кількість вхідних векторів набагато перевищує кількість векторів Вороного, що зазвичай відбувається на практиці. Алгоритм квантування векторів навчання (LVQ1) можна описати в такий спосіб.

1. Припустимо, що вектор Вороного w_c є найближчим до вхідного вектора x_i . Позначимо символом C_{w_c} клас, що асоціюється з вектором Вороного w_c , а символом C_{x_i} - Мітки класу вхідного вектора x_i . Вектор Вороного w_c коригується так.

a) Якщо $C_{w_c} = C_{x_i}$ то

$$w_c(n+1) = w_c(n) + a_n[x_i - w_c(n)], \text{ де } 0 < a_n < 1.$$

b) Якщо $C_{w_c} \neq C_{x_i}$, то

$$w_c(n+1) = w_c(n) - a_n[x_i - w_c(n)].$$

2. Інші вектори Вороного не змінюються.

Використана в алгоритмі константа навчання a_n задається монотонноспадною зі збільшенням числа ітерацій.

2.7. Адаптивна класифікація множин

У задачі класифікації попередньо підготовлених множин першим і найважливішим кроком є отримання ознак, яке виконується без учителя. Метою цього кроку є вибір обґрунтовано малої кількості ознак, у яких сконцентрована найістотніша інформація про вхідні (класифіковані) МД. Для отримання ознак

найкраще підходить самоорганізується карта, зважаючи на її властивості 4 (див. п. 2.1), особливо враховуючи, що множини вхідних даних формуються нелінійним процесом.

Другим кроком у задачі класифікації множин є сама класифікація, в якій ознаками, виділеними на першому кроці, призначаються різні класи. Незважаючи на те, що і сама організована карта може самостійно здійснювати класифікацію, все ж таки для підвищення продуктивності алгоритм буде доповнено схемою навчання з учителем. Комбінація картки, що самоорганізується, зі схемою навчання з учителем формує базис адаптивної класифікації множин, яка є гібридною за своєю сутністю.

Гібридний підхід до класифікації досягається використанням квантування вектора навчання, як було описано вище. Виходячи зі сказаного, отримаємо двоступінчастий адаптивний класифікатор (див. рисунок 2.10).

На рисунку 2.10 а показана двомірна карта ознак, що складається з решітки розміром 5×5 нейронів після завершення роботи алгоритму SOM.

Ця карта була маркована, і кожен з нейронів був поставлений у відповідність одному з провісників, залежно від того, як він зреагував на тестові дані, взяті із вхідного розподілу. На рисунку 2.10, б показана межа рішень, сформована самою картою ознак.

На рисунку 2.10, в показана модифікована карта ознак, налаштована в процесі навчання з вчителем на основі алгоритму DBSCAN. На рисунку 2.10, г показана межа рішень, отримана в результаті спільної дії алгоритмів SOM і DBSCAN. Порівнюючи останні два малюнки зі своїми двійниками, 2.10, а й 2.10, б, можна побачити якісний ефект застосування алгоритму DBSCAN.

У таблиці 2.10 представлені ефективності класифікації для карти ознак, що діє самостійно, і суміщення алгоритмів SOM і DBSCAN. Подані тут результати отримані з 10 незалежних пробних експериментів, у кожній з яких використовувалося по 30000 прикладів тестових даних. Графік розподілу даних, що використовуються під час проведення моделювання, показаний на рисунку 2.11.

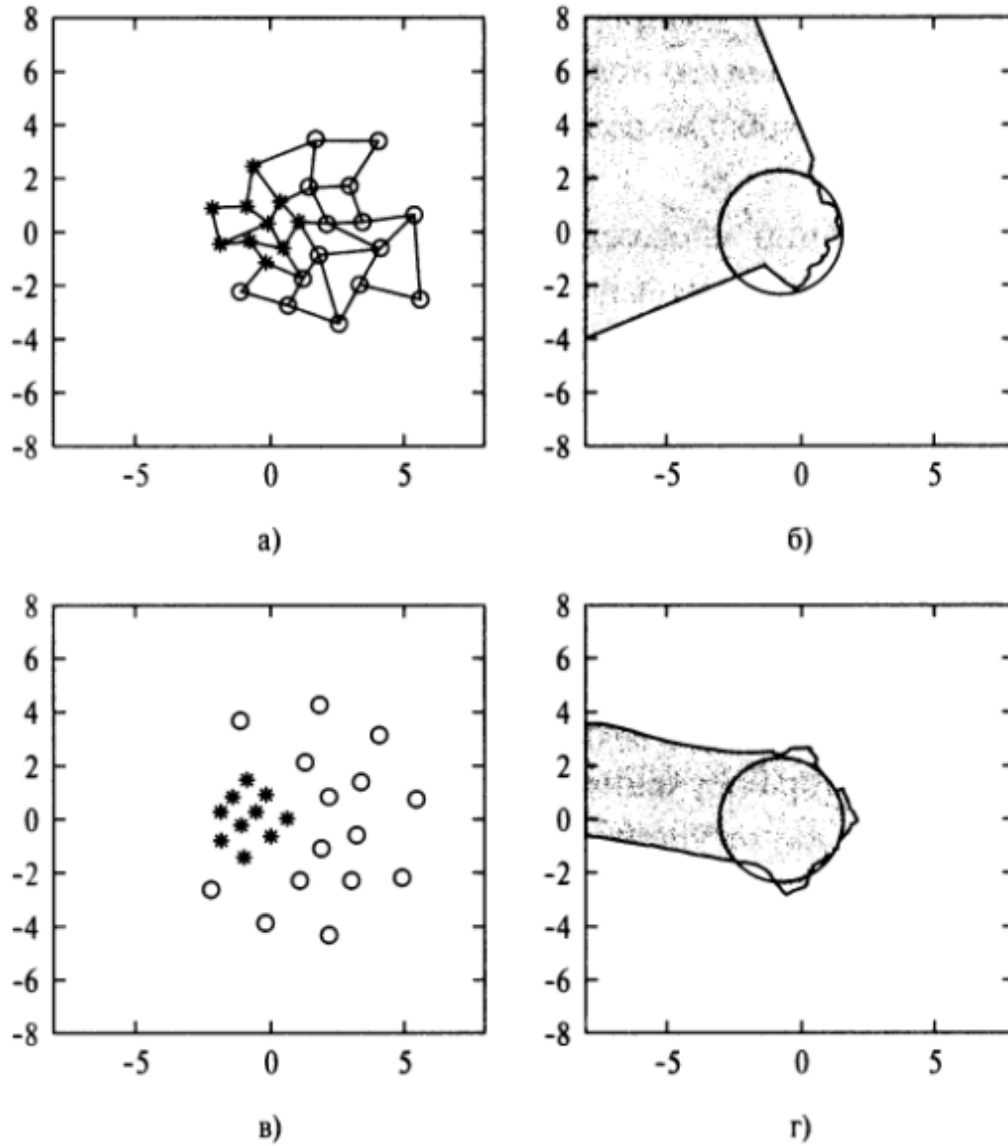


Рисунок 2.10 – Карта, що самоорганізується після розміщення міток (а). Кордон рішень (б), побудована карткою (а). Маркована карта після квантування векторів навчання (в). Кордон рішень (г), побудований на карті (в)

У кожному експерименті спостерігали підвищення якості класифікації при застосуванні алгоритму DBSCAN. Середній показник продуктивності для карти ознак, що діє самостійно, становив 79,61%, а комбінації двох алгоритмів - 80,52%, тобто. середнє поліпшення якості класифікації становило 0,91%.




Рисунок 2.11 – Функції густини ймовірності для експерименту

Для порівняння – продуктивність оптимального класифікатора Байеса [56] для цього експерименту становила 81,51%.

Таблиця 2.1 – Ефективність класифікації (у відсотках)

Спроба	Самостійна класифікація картою ознак	Класифікація комбінацією карти ознак та DBSCAN
1	79,05	80,18
2	79,79	80,56
3	79,41	81,17
4	79,38	79,84
5	80,30	80,43
6	79,55	80,36
7	79,79	80,86
8	78,48	80,21
9	80,00	80,51
10	80,32	81,06
Середнє	79,61%	80,52%

2.8. Ієрархічне квантування векторів

Необхідно відзначити, що найкращого стиснення даних завжди можна добитися за допомогою кодування не векторів, а скалярів, навіть якщо джерело даних не має пам'яті (тобто є послідовністю незалежних випадкових змінних), або якщо система стиснення даних має пам'ять (тобто. дії кодувальника залежать від своїх попередніх входів чи виходів) [68].

Однак алгоритми звичайного векторного квантування вимагають достатнього великого обсягу обчислень, що обмежує їх практичне використання. Більшість часу в алгоритмі векторного квантування займає операція кодування. При кодуванні вхідний вектор повинен порівнюватися з кожним вектором кодування в кодовій книзі, для того щоб знайти той, який забезпечує мінімальне спотворення. Наприклад, якщо кодова книга містить N векторів кодування, час, витрачений на кодування, матиме порядок N . Виходячи з цього, зі збільшенням N воно зростатиме. [81] описано багатоступінчасте ієрархічне кодування, яке буде застосовано при стисканні вихідних МД, що значно збільшує швидкість кодування. Використовуваний алгоритм ієрархічного кодування є багатоступінчастим векторним ієрархічним квантувачем, що використовує принцип розкладання операції векторного квантування на безліч підоперацій, кожна з яких вимагає малого (в порівнянні з вихідним) обсягу обчислень. Використовуючи механізм підготовки даних (квантування), описаний у розділі 1 та модифікований алгоритм SOM для навчання кожної з підоперацій, можна досягти малої втрати точності (до частки децибелу) при одночасному підвищенні швидкості обчислень.

Розглянемо роботу двоступінчастого векторного квантувача, $VQ1$ та $VQ2$, що використовується при оцінці МД. Перший передає свій вихід на другий. Вихід другого квантувача є остаточною версією кодової вихідного вхідного сигналу, застосованого до $VQ1$. При здійсненні квантування необхідно домогтися, щоб $VQ2$ не збіднював (враховував усі статистично значущі дані) вихідну інформацію. Оскільки розглядається квантувач $VQ1$ винятковий ефект від $VQ2$ полягає у

спотворенні виходу $VQ1$. Таким чином, виходить, що для $VQ1$ більше підходить алгоритм SOM, який враховує спотворення сигналу, що накладається квантувачем $VQ2$ [81]. Для того щоб використовувати узагальнений алгоритм Ллойда для навчання квантувача $VQ2$, потрібно припустити, що вихід $VQ2$ не буде спотворений до відновлення. У цьому випадку не потрібно вводити зашумлену модель (для виходу $VQ2$) та асоційовану з нею функцію околиці кінцевої ширини.

Узагальнення цього аргументу на багатоступінчастий вектор квантувач дозволяє використовувати наступне правило - кожен крок повинен враховувати спотворення, привнесені всіма попередніми кроками, та моделювати їх як шум. Тому для навчання всіх щаблів квантувача (за винятком останньої, для якої застосовується узагальнений алгоритм Ллойда) використовується алгоритм SOM.

Ієрархічне векторне квантування є окремим випадком багатоступінчастого векторного квантування [81]. Як ілюстрація розглянемо квантування вхідного вектора розмірності 4×1 : $x = [x_1, x_2, x_3, x_4]^T$.

На рисунку 2.12, а показано одноступінчастий векторний квантувач для x . Як альтернатива використовується двоступінчастий ієрархічний квантувальник, поданий на рисунку 2.12, б. Кардинальна відмінність між двома цими схемами у тому, що розмірність входу квантувача на рисунку 2.12, а дорівнює чотирьом, тоді як квантувача на рисунку 2.12, б - двом. Відповідно квантувач, представлений на рис 2.12, б, вимагає для своєї роботи істотно меншої довідкової таблиці та є більш простим для реалізації, ніж квантувач, показаний на рисунку 2.12, а. У цьому й лежить Основна перевага ієрархічного квантувача перед традиційним [61].

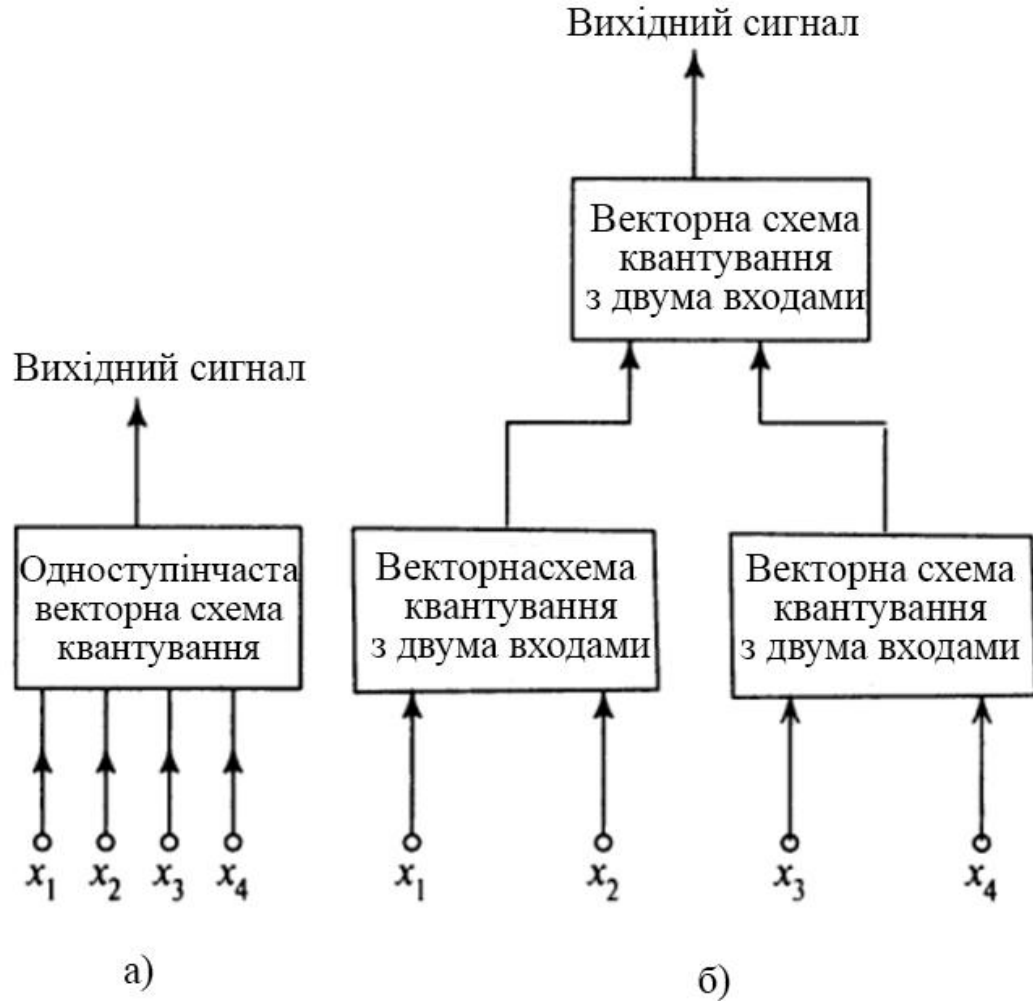


Рисунок 2.12 – Одноступінчастий вектор квантувач з чотиривимірним вхідним сигналом (а); двоступінчастий векторний ієрархічний квантувач, що використовує двовходові векторні квантувачі (б)

На рисунку 2.13 відтворено результати, отримані у цій роботі, для випадку корелированого гауссового шуму, що генерується за допомогою використовуваного у роботі методу: $x(n + 1) = \rho x(n) + v(n)$,

де ρ - коефіцієнт авторегресії; $v(n)$, - незалежна та рівномірно розподілена гауссова випадкова змінна з нульовим середнім та одиничним дисперсією.

Виходячи з цього, можна показати, що $x(n)$ характеризується наступним чином: $E[x(n)] = 0, E[x^2(n)] = \frac{1}{1-\rho^2}, \frac{E[x(n+1)x(n)]}{E[x^2(n)]} = \rho$

Таким чином, ρ можна розглядати як коефіцієнт кореляції часового ряду. Щоб ініціювати генерацію цього часового ряду, для $x(0)$ використана гауссова випадкова змінна з нульовим середнім та дисперсією $\frac{1}{1-\rho^2}$, а як коефіцієнт кореляції обрана величина $\rho = 0,85$.

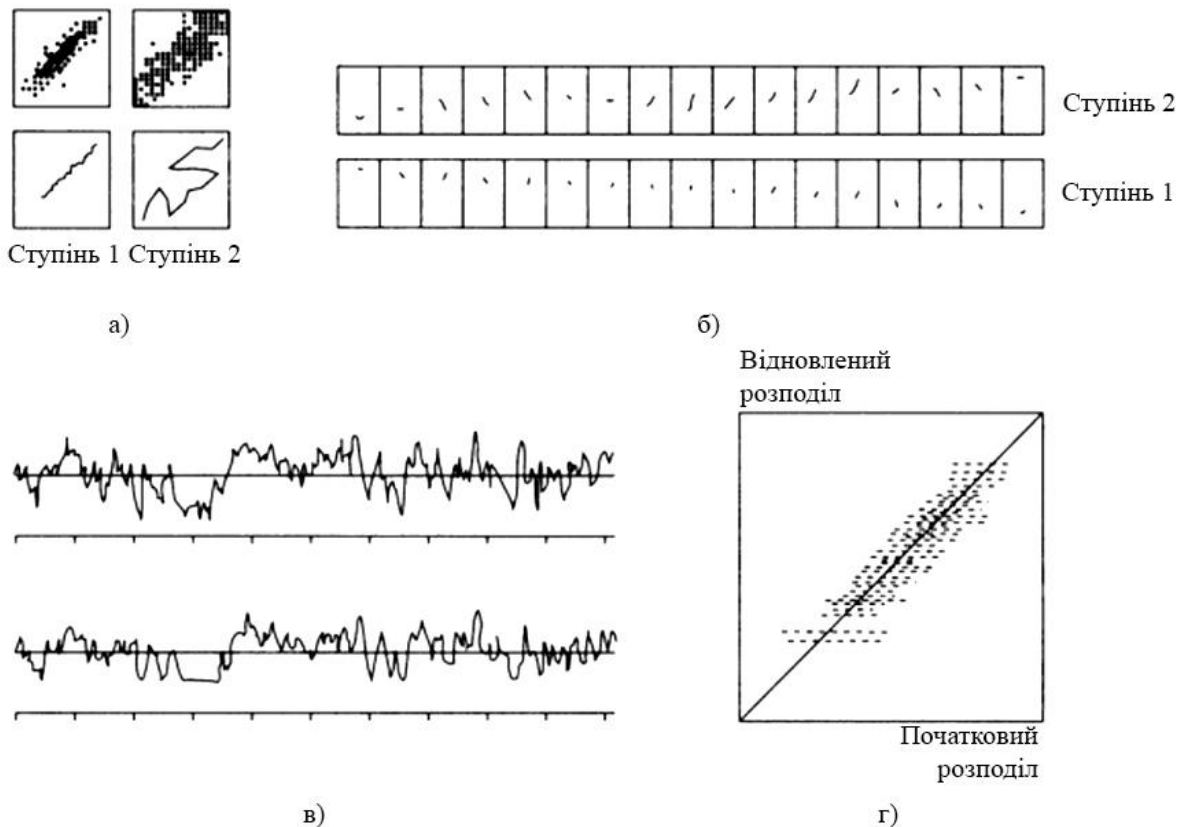


Рисунок 2.13 – Результати двоступеневого кодування/декодування для корельованого гаусового шуму. Коефіцієнт кореляції $\rho = 0,85$

Для векторного квантування використовувався алгоритм АК із чотиривимірним вхідним простором, подібний до показаного на рисунку 2.13, б. Для ряду авторегресії $\{x(n)\}$ знадобилася симетрія перетворення, що передбачає використання лише двох окремих довідкових таблиць. Розмір кожної з цих таблиць

експоненційно залежав від кількості бітів вхідного сигналу та лінійно кількості бітів вихідного сигналу. Під час навчання для правильного обчислення корекцій знадобилася велика кількість бітів для представлення чисел, тому під час навчання довідкові таблиці не використовувалися. Після закінчення навчання кількість бітів могла бути зменшена до звичайного рівня, після чого були потрібні записи довідкових таблиць. Для кодера, показаного на рис 2.13 б, вхідні образи апроксимувалися з використанням чотирьох бітів на образ. Для всіх ступенів кодера використовувалось $N = 17$ векторів кодування, так що кількість вихідних бітів у кожній з довідкових таблиць приблизно дорівнювала чотирьом. Таким чином, розмір адресного простору для таблиць обох ступенів становить $256 (= 24+4)$. Це свідчить, що загальні вимоги до пам'яті подання таблиць були невеликими. На рисунку 2.13 показані результати кодування/декодування елементів $x(n)$. У нижній частині рисунку 2.13, а вектори кодування для кожної з двох ступенів показані як криві, поміщені в двовимірний вхідний простір. У верхній частині рисунку 2.13, а показані оцінки відповідних матриць відповідності розміром 16×16 . На рисунку 2.13 у вигляді фрагментів тимчасового ряду представлені наступні елементи:

- вектор кодування, обчислений першим ступенем кодера;
- вектор відновлення, обчислений другим ступенем, який мінімізує середньоквадратичне спотворення при одночасному збереженні всіх інших змінних.

На рисунку 2.13, в представлено 512 прикладів з вихідного часового ряду (верхня крива) спільно з реконструйованими прикладами (нижня крива). Ці дані взяті з виходу останнього ступеня кодувальника. Горизонтальна шкала на рисунку 2.3, дорівнює половині шкали на рисунку 2.13, б. На рисунку 2.3, г представлена матриця відповідності, складена з пар прикладів - вихідних та відповідних їм відновлених. Ширина смуги на рисунку 2.13, г показує ступінь спотворення, зробленого ієрархічним векторним квантуванням.

Досліджуючи графіки на рисунку 2.13, в, можна побачити, що відновлена інформація є досить гарним уявленням вихідного тимчасового ряду, за винятком

того, що окремі позитивні та негативні піки зрізані. Нормоване середньоквадратичне відхилення становило 0,15, що практично не гірше (менше на 0,05 дБ), ніж 8,8 дБ, отримані з використанням одноступінчастого блокового кодера з чотирма входами, що використовує по одному біту на приклад.

2.9. Відображення результатів аналізу

Існують два фундаментально відмінні методи візуалізації самоорганізованих карт ознак. Перший із цих методів полягає у побудові гнучкої мережі, у якій вектори синаптичних ваг є показниками, спрямованими від відповідних нейронів у вхідний простір. Цей метод візуалізації є особливо корисним для правильного відображення властивості топологічного впорядкування алгоритму SOM. Це було показано на прикладі комп'ютерного моделювання, наведеного в розділі 2.6.

У другому методі візуалізації нейронам у двовимірній решітці (що представляє вихідний шар мережі) призначаються мітки класів, залежно від того, як кожен з прикладів (що не зустрічалися раніше) порушив конкретний нейрон в мережі, що самоорганізується. В результаті цього другого ступеня моделювання нейрони в двовимірній решітці розбиваються на кілька когерентних областей. Під когерентністю розуміється те, кожна з груп нейронів представляє відокремлене безліч безперервних символів чи міток [69]. Це передбачає, що з відновлення добре упорядкованої карти використовувалися правильні умови.

Наприклад розглянемо безліч даних, поданих у таблиці 2.2. У цій таблиці наведено характеристики окремих МП за вибраним регіоном. На підставі даних кожного зі стовпців таблиці можна скласти метеорологічний прогноз для обраного регіону за наданими МД з урахуванням змін ретроспективного періоду. МД, отримані з відкритих джерел, позначилися так: МП1 - середня швидкість горизонтального вітру в м/с; МП2 - середній напрям гірського вітру в °С; МП3 – мінімальна швидкість миттєвого гірського вітру м/с; МП4 - максимальна швидкість миттєвого гірського вітру в м/с; МП5 – середня швидкість вертикального вітру м/с; МП6 – атмосферний тиск у мм. рт. ст.; МП7 - відносна вологість повітря у %; МП8 -

температура точки роси в °С; МП9 - пружність (тиск) водяної пари в гПа; МП10 - абсолютна вологість у г/м³; МП11 - щільність повітря в г/м³; МП12 - швидкість звуку повітря в м/с.

Таблиця 2.2 – Характеристики окремих МП у регіоні

Ретро-й аналіз МП	Значення відменнос тей МП, в %	МП 1	МП 2	МП 3	МП 4	МП 5	МП 6	МП 7	МП 8	МП 9	МП 10	МП 11	МП 12
Знижувалис я	МП 2%	0	0	1	0	1	0	1	0	1	0	0	0
	МП 10%	0	0	1	1	1	0	1	0	1	0	0	0
	МП 20%	0	0	1	1	1	0	1	0	1	0	0	0
	МП 50%	0	1	0	0	0	1	0	0	0	0	1	1
	МП 80%	0	1	0	1	1	0	1	1	0	0	1	0
Підвищувал ися	МП 2%	0	0	1	1	1	0	1	0	1	0	0	0
	МП 10%	0	1	0	0	0	1	0	0	0	0	1	1
	МП 20%	0	0	1	1	1	0	1	0	1	0	0	0
	МП 50%	0	0	1	1	1	0	1	0	1	0	0	0
	МП 80%	0	0	1	1	1	0	1	0	1	0	0	0

При цьому значення 1 має на увазі наявність, а 0 - відсутність (зниження, підвищення) одного з 12 метеорологічних параметрів, перерахованих у стовпчик зліва. Окремі МП (наприклад, «МП7» і «МП8») корелюють, час як інші – ні. Для кожного з аналізованих регіонів можна скласти характеристичний код xa , що складається із дванадцяти елементів. Регіон визначається символічним кодом xs , за яким ніяк не можна зібрати інформацію про подібності та відмінності між окремими МП. Наприклад, в даному прикладі xs являє собою вектор, k -й елемент (відповідний номеру МП у списку) якого має деяке значення a - при цьому все інші елементи дорівнюють нулю. Параметр a визначає відносний вплив характеристичного та символічного кодів один на одного. Для того щоб гарантувати, що цей

характеристичний код є доміантним, a вибирається рівним 0,2. Вхідний вектор для кожного МП складається з 29 елементів і є об'єднання характеристичного x_a і символічного x_s кодів:

$$x = \begin{bmatrix} x_s \\ x_a \end{bmatrix} = \begin{bmatrix} x_s \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ x_s \end{bmatrix}.$$

Нарешті, кожен із векторів даних нормується до одиничної довжини. Приклади з таким чином створеної множини даних подаються на вхід двовимірних ґрат нейронів розміром 10x10, при цьому синаптичні ваги нейронів налаштовуються відповідно до алгоритму SOM (див. рисунок 2.1). Навчання тривало протягом 2000 ітерацій, після чого карта ознак мала досягти стабільного стану. Після цього в мережі, що самоорганізується, подавалися на вхід вектори $x = [x_s, 0]^T$, що містять тільки символічні коди МП, і визначався нейрон з найсильнішим відгуком. Ця процедура повторювалася всім дванадцятьма МП.

У ній марковані нейрони дали найсильніший відгук відповідні приклади. Крапками на карті позначені нейрони з слабкішими відгуками.

У процесі виконання описаного алгоритму було отримано карту, показану на рисунку 2.14.




Рисунок 2.14 – Карта ознак, що містить марковані нейрони, що мають найбільше сильний відгук на певний вхідний приклад

На рисунку 2.15 показаний результат моделювання для тієї ж мережі, що самоорганізується. Однак цього разу кожен із нейронів мережі був маркований назвою того МП, для якого його відгук був найсильнішим. На цьому малюнку видно, що карта ознак чітко відстежує «родинні взаємозв'язки» між 12 різними ознаками. На ньому можна виділити три відокремлені кластери, один з яких представляє регіони з підвищеним значенням, другий – із середньою, а третій – із низьким значенням обраного МП. Необхідно враховувати, що значення коефіцієнтів навмисно встановлювалися в бінарне значення, визначення взаємозв'язку кластеризації. Реальні значення коефіцієнтів параметрів лежать у ширших діапазонах і розподілені так, що їх аналіз дозволяє однозначно визначити ймовірності зміни у більшу чи меншу сторону.

Карта ознак, показаних на рисунку 2.15 називається контекстною або семантичною [18], [16]. Отримані у роботі контекстні карти, отримані внаслідок використання алгоритму SOM, можуть застосовуватися у вирішенні завдань аналізу каталогів МД чи дослідженні МП і витягу з них прихованих закономірностей [16].



Рисунок 2.15 – Семантична карта, отримана під час використання моделювання

Запропонований у роботі алгоритм аналізу МП на основі самоорганізованих карти є нейронною мережею, побудованою на одно- або двовимірній решітці нейронів для отримання важливих ознак, що містяться у вхідному просторі. Таким

чином, можна отримати структурне подання вхідних даних, використовуючи як прототипи вектори ваги нейронів. Алгоритм SOM має нейробіологічне підґрунтя. Він об'єднав у собі всі основні механізми, властиві самоорганізації: конкуренцію, кооперацію та самопосилення (див. розділ 1). Таким чином, його можна розглядати як універсальний, незважаючи на неповний розвиток моделі, що описує виникнення явища колективного порядку в складних системах, що починаються з повного безладдя.

Карті, що самоорганізуються, можна також розглядати як векторний квантувальник, реалізуючи таким чином важливий підхід до висновку правила корекції, що використовується для налаштування векторів ваг [94]. Цей останній підхід ще раз наголошує на ролі функції околиці, виступає у ролі функції щільності ймовірності.

У [18] показано, що динаміка навчання самоорганізується карти на етапі упорядкування адаптивного процесу (тобто під час топологічного впорядкування спочатку безладної карти ознак) не може бути описано стохастичним градієнтним спуском з однією функцією вартості. Однак у разі одномірної решітки цей процес може бути описаний з використанням безлічі функцій вартості - по одній для кожного нейрона мережі. При цьому ці функції незалежно мінімізуються відповідно до методом стохастичного градієнтного спуску.

В алгоритмі SOM дивує те, наскільки він легко реалізований, і при цьому досить складно аналізувати його властивості, використовуючи математичний апарат. Для його аналізу деякими дослідниками було запропоновано низку потужних методів, проте їх результати мають обмежену область застосування. У [25] був наведений огляд результатів, отриманих у теоретичні аспекти алгоритму SOM. Зокрема, було підкреслено недавні результати, отримані в [25], [18], де стверджувалося, що у випадку одномірної решітки можна отримати суворий доказ збіжності алгоритму SOM до єдиного стану після проходження ним етапу

самоорганізації. Цей важливий результат був показаний для досить широкого класу функцій околиці. Однак те ж саме не можна стверджувати для багатовимірних ґрат.

Було зазначено, що використання алгоритму SOM дозволяє отримати деякий порядок для аналізу ознак. Так самоорганізовані карти здатні виявити ряд ознак та візуально підтвердити наявність репрезентативних даних з допомогою формування обчислювальних карт. За деяких припущень було показано, що навчання Хебба веде до створення упорядкованих просторових моделей орієнтації із зазначенням домінуючих ознак на основі багатокритеріального аналізу.

Висновок до 2 розділу

Для навчання мережі був вибраний алгоритм SOM. У процесі виконання описаного алгоритму було отримано карту, показану на рисунку 2.14. Даний алгоритм аналізу МП на основі самоорганізовані карти є нейронною мережею, побудованою на одно- або двовимірній решітці нейронів для отримання важливих ознак, що містяться у вхідному просторі. Таким чином, можна отримати структурне подання вхідних даних, використовуючи як прототипи вектори ваги нейронів. Алгоритм SOM має нейробіологічне підґрунтя. Він об'єднав у собі всі основні механізми, властиві самоорганізації: конкуренцію, кооперацію та самопосилення. Таким чином, його можна розглядати як універсальний, незважаючи на неповний розвиток моделі, що описує виникнення явища колективного порядку в складних системах, що починаються з повного безладдя.

РОЗДІЛ 3

СТВОРЕННЯ МОДЕЛІ ПРОГНОЗУВАННЯ ПОГОДИ

3.1. Розробка оперативного прогнозування погоди на основі властивостей «потрійного входу» числових моделей

Оперативне прогнозування погоди [25] досягло переломного моменту. Цілком можливо, що вона може бути переформована властивостями «Triple-In» «незамінності», «неточності» та «неповноти» числових моделей. Важливою особливістю поточного оперативного прогнозування погоди є необхідність числових моделей. Але неточність корениться майже в усіх числових схемах, а неповнота чисельних моделей завжди буде існувати через надзвичайну складність системи Землі.

Властивості Triple-In в числових моделях визначають прогрес метеорологічного розвитку, а також майбутні рамки оперативного прогнозування погоди. Незамінність означає, що чисельна модель має здатність і потенціал для опису еволюції атмосфери або системи Землі – кардинальний принцип для стратегічного плану метеорологічного прогресу. Але неточність і неповнота показують, що продукти, отримані безпосередньо з числового прогнозу погоди (ЧПП), містять невизначеності. Тому оновлена операція повинна бути зосереджена на мінімізації неминучих невизначеностей. Неточність вимагає докласти зусиль для підвищення точності ЧПП у метеорологічних центрах. Неповнота підкреслює, що для моделювання системи Землі потрібні додаткові атрибути дослідження.

З кінця двадцятого століття Національна академія наук Сполучених Штатів (NAS) досліджує, як національні метеорологічні служби можуть постійно покращувати прогнози погоди та відповідні продукти та послуги (Національна дослідницька рада, 1999). У «дорожній карті» на майбутнє НАН наголосила на необхідності та можливостях продовження модернізації. Нещодавній оглядовий документ (Benjamin et al, 2019), який простежив еволюцію прогнозування за останні 100 років, розділивши їх на чотири ери, вказував, що наступні 30 років будуть новою

ерою. Його характеристики будуть включати, наприклад, більшу автоматизацію процесу прогнозування та все більшу складність у всіх масштабах часу/простору для чисельного прогнозування погоди навколишнього середовища.

Про те, чи можна буде проводити прогноз погоди на основі наукових, математичних принципів, серйозно обговорювали понад 100 років тому. Теоретичні розробки з тих пір дали розуміння атмосферної динаміки та фізичних процесів, що створює основу для чисельних моделей і суттєво сприяє безперервному вдосконаленню експлуатаційних ЧПП. Взявши за приклад еволюцію продуктів реаналізуна рисунку 3.1 показано кліматичні літні осадки, отримані з продуктів Глобального проекту по кліматології осадків (GPCP) та різних продуктів реаналізу над Східною Азією.

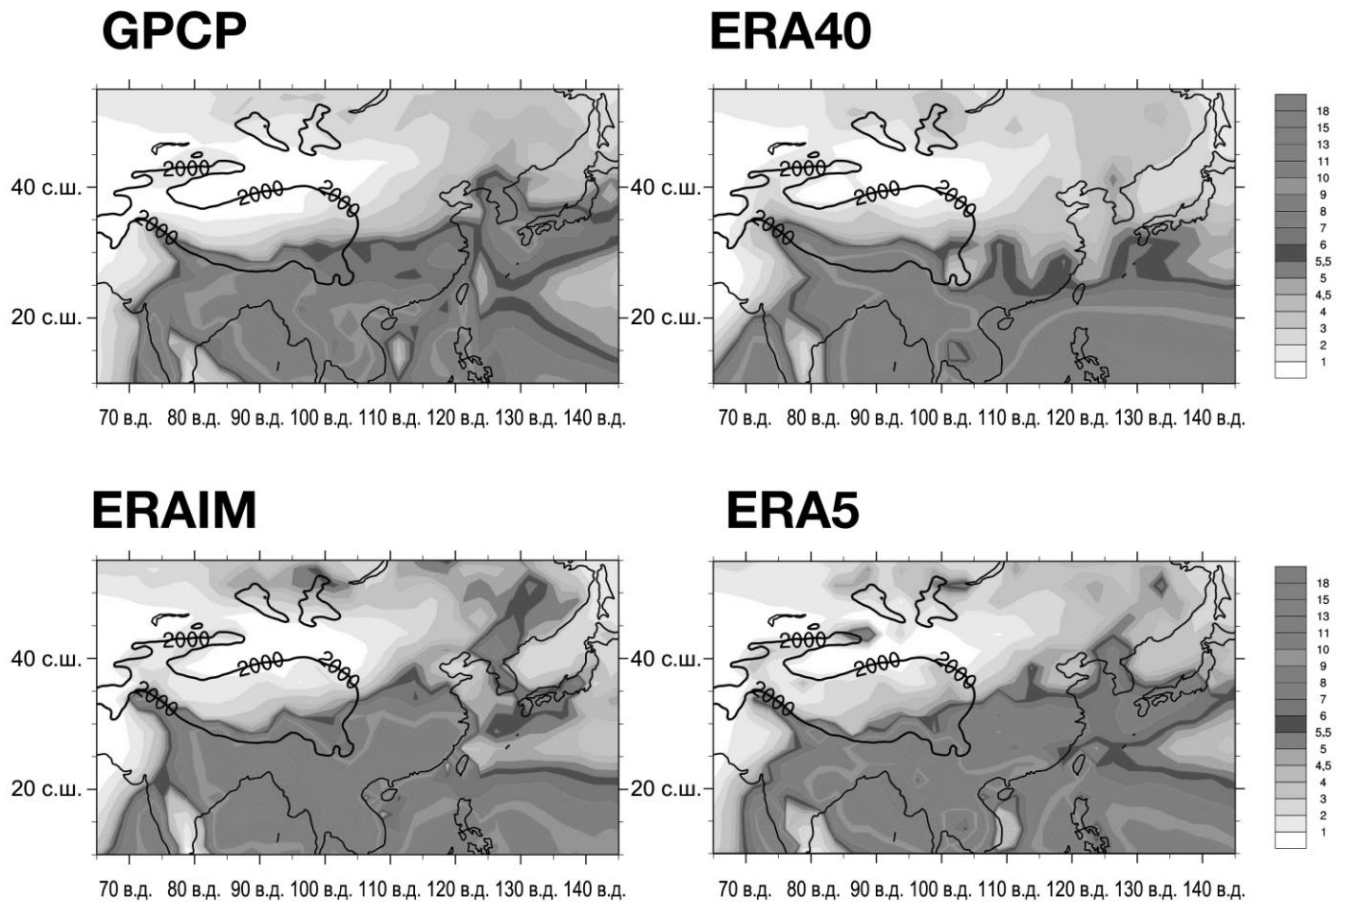


Рисунок 3.1– Кліматичні літні опади (1979-2002 рр.)

Опади з даних повторного аналізу можуть відображати здатність чисельних моделей створювати всі процеси, пов'язані з опадами. Як показано на рисунку 3.1, порівняно з GPCP, ERA40 (на основі моделі, випущеної в 2001 році) значно недооцінює опади над Східною Азією, особливо над південно-східним Китаєм. Навпаки, ERA-Interim (модель, випущена в 2006 році) переоцінює кількість опадів у південно-східному Китаї. ERA5 (2016) обґрунтовано відтворює значення та структуру спостережуваних опадів. Відмінності між трьома поколіннями даних повторного аналізу підкреслюють значні вдосконалення систем чисельних моделей протягом багатьох років.

Triple-In – незамінність, неточність і неповнота – властивості притаманні чисельним моделям. Такі моделі незамінні для сучасного прогнозування погоди і стануть найважливішим компонентом для безперебійної цифрової роботи в майбутньому. Відповідно до цілісної системи системи Землі нової ери, моделі ЧПП просуваються до моделювання зрілої системи Землі.

Порівняння двох моделей ЧПП, що працюють з різними просторовими роздільними можливостями, та відповідного радіолокаційного QPE показано на рисунку 3.2. Деякі з основних особливостей позначаються овалами та дугоподібними вигинами. Для порівняння використовується експлуатаційний радіолокаційний QPE з подвійною поляризацією С-діапазону для субтропічного складного рельєфу Тайваню.

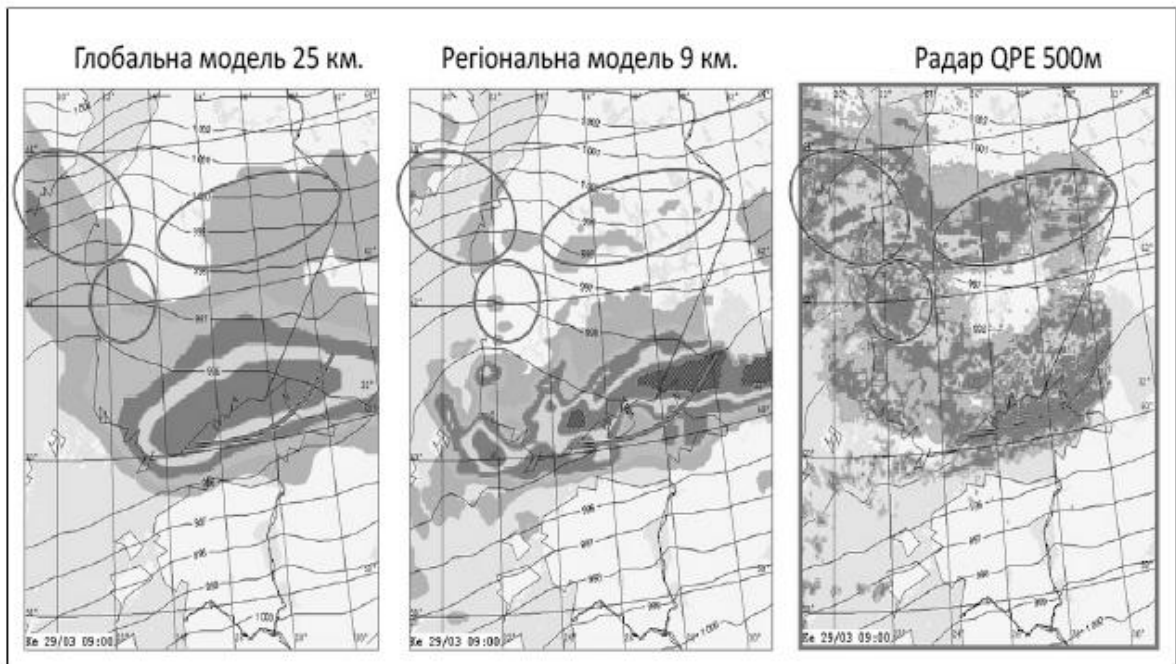


Рисунок 3.2 – Порівняння двох моделей ЧПП та радіолокаційного QPE

Однак система Землі є складною ієрархією, тому її числова модель також є складною. Відповідно, неточність і неповнота чисельної моделі завжди буде існувати скрізь і призведе до довгострокової невизначеності ЧПП. Така постійна невизначеність визначає напрямок розвитку метеорології, а також майбутню основу оперативного прогнозування погоди. До негативних якостей, що властиві чисельним моделям можемо віднести незамінність, неточність та неповноту.

Незамінність – Замість простої сукупності причинно-наслідкових зв'язків усі атмосферні явища є результатом комплексних впливів поєднання несинхронних, нерівномірних і нерівноважних факторів. Через величезну складність атмосферних процесів лише чисельна модель має здатність і потенціал для всебічного розуміння багатомасштабного та нелінійного впливу та опису розвитку атмосфери. У міру розвитку чисельного моделювання протягом останніх 30 років, ЧПП, який щодня виконується у великих оперативних центрах, безсумнівно, став домінуючим у процесі прогнозування. Тому необхідність числової моделі була важливою ознакою сучасного оперативного прогнозування.

Неточність – Відправною точкою для чисельної моделі є низка основних законів, що керують атмосферною динамікою: другий закон руху Ньютона, перший закон термодинаміки та закон збереження маси. Для збереження та обробки на комп'ютері змінні безперервного поля в рівняннях, що описують основні закони, повинні бути дискретизовані. Просторова та часова дискретизація може призвести до помилок.

Неповнота – На атмосферу істотно впливають інші компоненти земної системи. Світовий океан, кріосфера, поверхня суші, гідрологія, склад та екосистеми мають важливий вплив на прогноз погоди. Деякі взаємодії навколишнього середовища були включені в системи чисельного прогнозування протягом десятиліть. Завдяки прогресу в моделях атмосфери було реалізовано все більшу кількість взаємодіючих процесів між різними компонентами земної системи, і було вирішено більше деталей цих процесів.

Основу оперативного прогнозування погоди [33] слід оновити та перевизначити. Завдяки своїй незамінності чисельна модель для системи Землі, безумовно, стане центром оперативного прогнозування в наступній безперебійній ері. Постійні дослідження та розробки є єдиним способом подолати неточність і неповноту чисельних моделей. Властивості чисельних моделей Triple-In підкреслюють дослідницькі атрибути загальної метеорологічної діяльності. Як показано на рисунку 3.3, нову структуру оперативного прогнозу погоди можна розділити на чотири розділи.

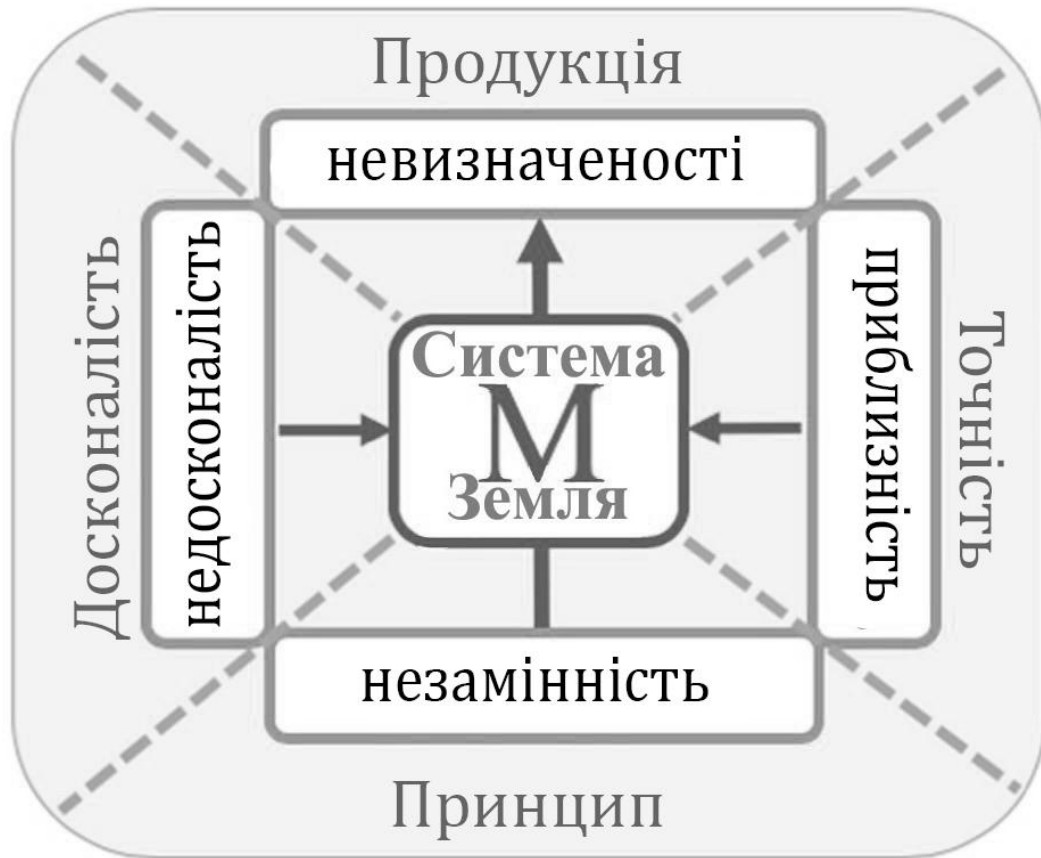


Рисунок 3.3– Нова структура оперативного прогнозування погоди

Стратегічне планування: до моделювання ідеальної цілісної системи Земля. У нижній чверті рисунку 3.4 необхідність числової моделі визначає стратегічний план майбутнього оперативного прогнозування: створення надійної безшовної системи моделювання системи Землі та найкраще використання результатів моделі об'єктивно. Це основний принцип проектування завдань наукового дослідження, технічного розвитку та експлуатації. Права та ліва чверті рисунку 3.4 показують розгортання для покращення поточних систем чисельних моделей, які спрямовані на точність та досконалість. Верхня чверть представляє зусилля щодо оптимізації результатів ЧПП з визнанням невизначеності.

Розвиток потенціалу для підвищення точності моделі – Права чверть рисунку 3.3 показує потребу в підвищенні точності моделі системи та в більш точних

та ефективних математичних виразах і числових методах, які необхідно розробити. Необхідно збільшити просторово-часову роздільну здатність, провести фундаментальні метеорологічні дослідження фізико-хімічних процесів, розробити більш надійні методи засвоєння даних. Враховуючи новий попит на безперервне передбачення, інноваційне та витончене оцінювання має бути розроблено та проведено, щоб зрозуміти та відстежити джерело упереджень у системі моделі. У той же час слід розробляти та проводити більше польових кампаній, щоб сприяти розумінню ключових динамічних і фізичних процесів в атмосфері та покращити продуктивність моделі. Наприклад, у Китаї були проведені Третій атмосферний науковий експеримент на Тибетському плато (TIPEX-III) (Zhao et al., 2018) і експеримент з опадами мусонних опадів у південному Китаї (SCMREX) (Luo et al., 2017).

Операційну систему ЧПП також слід оновити для підвищення точності. Наприклад, у короткостроковому прогнозуванні слід використовувати регіональні моделі високої роздільної здатності з чітко вирішеними мезомасштабними процесами. У центрі уваги в цьому просторово-часовому масштабі є швидкий цикл оновлення та залучення дрібномасштабного форсування, такого як складні міські або гірські кордони.

Прогноз сильних опадів над північною окраїною Сичуанського басейну (на південному заході Китаю) наведено як приклад на рисунку 3.4. Порівняння середнього добового розподілу опадів перед літом (травень–червень) з аналізу об'єднаних опадів Китаю (CMPA) (рисунок 3.4, *a*) та 24-годинний прогноз ESMWF (12–36 год) (рисунок 3.4, *b*) показує, що модельний прогноз загалом відтворює центри сильних опадів над південно-західним Китаєм. Розташування та величина центрів опадів є порівнянними в цільовому регіоні (позначені чорними пунктирними лініями на рисунку 3.4).

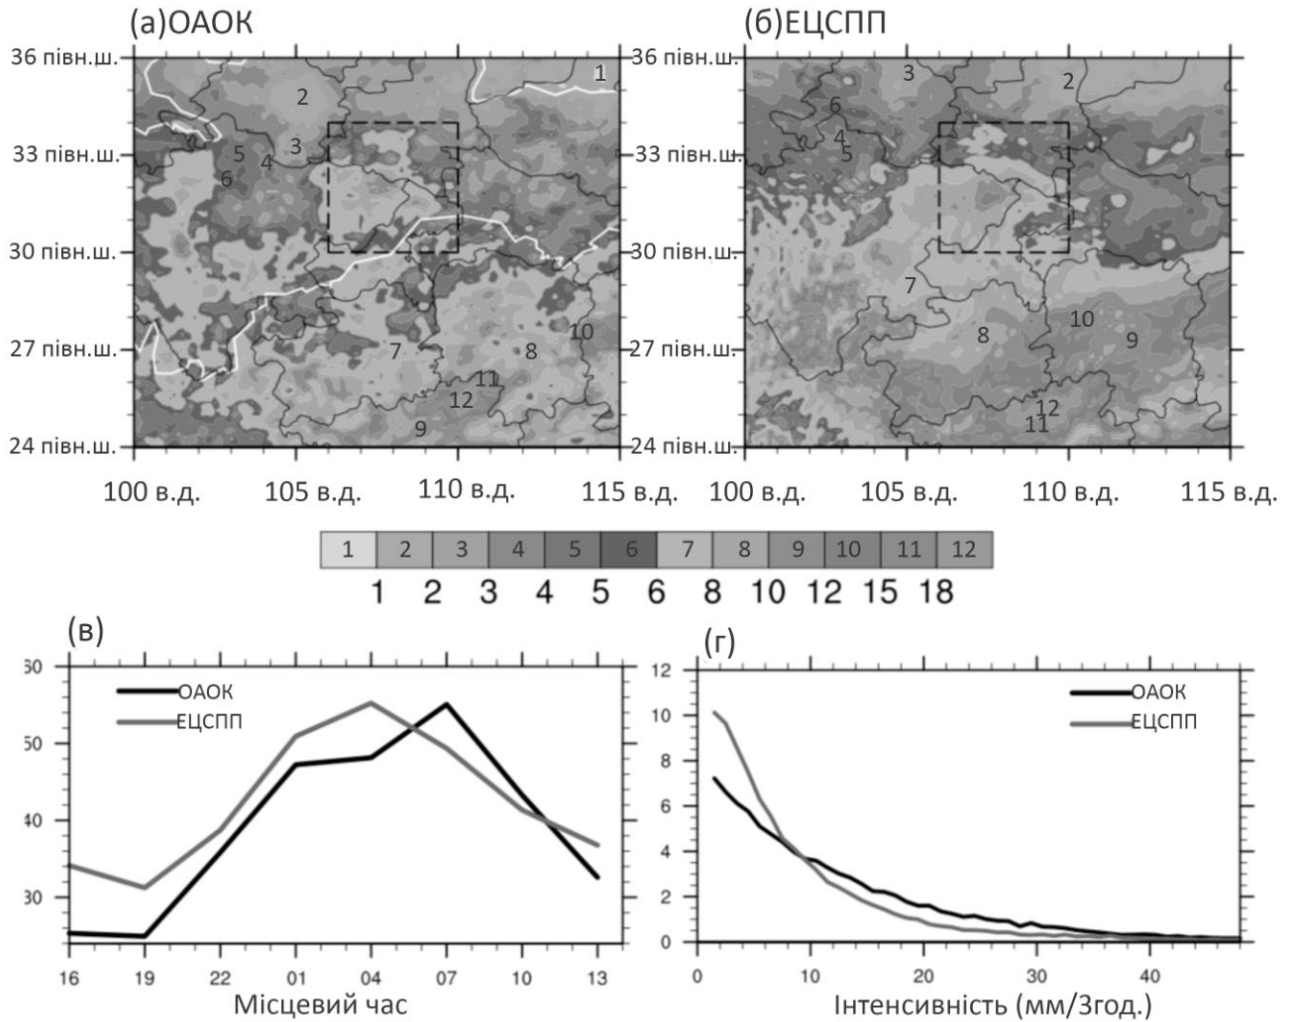


Рисунок 3.4 – Середня величина добових осадків (мм/доба) у північній частині Китаю за період з травня по червень 2019

На рисунку 3.4 ми можемо розглянути по даним спостережування (а), та прогноз моделі інтегрованої системи прогнозування ЕЦСПП за 12–36 години (б). Цільовий регіон над північним краєм басейну Сичуань позначено чорною пунктирною лінією. (в) Регіональні усереднені добові криві накопичених сильних опадів (з інтенсивністю в години пік понад 5 мм/3 год) у спостереженнях (чорна лінія) та модельному прогнозі (сіра лінія). (г) Усереднений по регіону відсоток загальної кількості опадів, розподілений з різною погодинною інтенсивністю для спостереження (чорна лінія) та модельного прогнозу (сіра лінія).

Для повного безперервного прогнозування погоди та навколишнього середовища слід використовувати модель системи «всієї» Землі. Зі збільшенням роздільної здатності моделі буде вирішено більше особливостей океану, морського льоду та поверхні суші, а також буде залучено та належним чином відтворено набагато ширший спектр хімічних та біологічних процесів.

Робота в режимі реального часу: розуміння невизначеностей у продуктах та розробка об'єктивних алгоритмів та корекцій – По-перше, необхідно покращити наукове розуміння особливостей погоди та клімату в тонкому масштабі та безперервно. По-друге, необхідно розробити точні метрики для оцінки поведінки ключової моделі та критичних процесів, а також для розуміння невизначеності. По-третє, на основі поглибленої оцінки необхідно добре використовувати великі дані та впроваджувати інноваційні автоматичні методи для об'єктивної корекції продуктів системи чисельного прогнозування. Завдяки найсучаснішій валідації та виправленню прогнозист може мінімізувати невизначеність поточної системи чисельних моделей і створити високоякісний прогноз.

3.2. Сучасні проблеми і методи прогнозу погоди та аналізу в Україні

3.2.1. Розробка регіональних мезомасштабних моделей – шлях підвищення якості прогнозу

Більшість крупномасштабних прогностичних моделей описують атмосферні процеси з недостатнім для локального прогнозу просторовим дозволом (горизонтальний крок сітки становить близько 300 км). За допомогою таких моделей можна прогнозувати деякий посередній стан погоди або, як іноді кажуть, її фон. Але на тлі великомасштабних синоптичних процесів в атмосфері розвиваються процеси менших масштабів, з яких найбільший інтерес становлять процеси підсиноптичного масштабу та мезомасштабу. Ці процеси роблять істотний внесок у формування погоди в окремих областях і пунктах.

Тому для України розробка та впровадження в оперативну практику мезомасштабного чисельного прогнозу є основним напрямом підвищення якості прогнозів погоди. Завдання вирішується на основі повної системи рівнянь у гідростатичному та негідростатичному наближеннях. Як вихідна інформація поряд з даними мережі метеорологічних станцій та пунктів радіозондування використовуються також спостереження локальної мережі підвищеної щільності для обмеженої прогностичної області. Перехід до регіональних прогностичних моделей вимагає більш точного обліку особливостей рельєфу місцевості, неоднорідностей поверхні, що підстилає (наприклад, суша-море), неадіабатичних приток тепла. Проблеми, що виникають при цьому, пов'язані із завданням граничних умов на бічних межах області розрахунку, описом взаємодії велико- і мезомасштабних процесів, створенням ефективної чисельної схеми вирішення системи рівнянь гідротермодинаміки з високим рівнем турбулентного замикання. На базі мезомасштабних і локальних моделей розраховується детальний прогноз погоди (крок по горизонталі – кілька кілометрів), що включає хмарність, опади, екстремальні температури, локальні вітри. Подібні дослідження слід відносити до пріоритетних.

Як впливає з вищевикладеного, подальший розвиток методів аналізу та прогнозу погоди в умовах України логічно пов'язаний із розробкою та впровадженням моделі локального гідродинамічного прогнозу погоди. Це визначається принаймні двома обставинами.

По-перше, існуюча ієрархія метеорологічних центрів Всесвітньої служби погоди включає Національні метеорологічні центри (НМЦ), Регіональні метеорологічні центри (РМЦ), та Світові метеорологічні центри (ММЦ). В області прогнозування погоди ММЦ та РМЦ відповідальні за прогнози глобального та напівсферного масштабу на строк до 10 діб. Обов'язком НМЦ є забезпечення споживачів додаткової прогностичної інформацією, одержуваної за допомогою відповідних прогностичних методик на основі прогностичної продукції ММЦ і РМЦ.

Інструментом, який може суттєво розширити та наблизити до споживача прогностичну продукцію ММЦ та РМЦ, є моделі локального прогнозу (МЛП).

По-друге, подальше поліпшення якості локальних прогнозів пов'язані з більш точним урахуванням впливу місцевих, мезомасштабних особливостей розвитку атмосферних процесів у режимі. Незважаючи на дуже високий рівень розвитку існуючих глобальних і напівсферних прогностичних систем, необхідні більш високий просторовий дозвіл і ретельніший облік тих конкретних фізичних процесів, які є важливими для даного географічного району (і водночас не є пріоритетними для великомасштабних прогностичних систем). За допомогою МЛП можна отримати детальні короткострокові прогнози погоди.

Заслуговує на увагу ще один аспект цієї проблеми. Наразі є гостра необхідність у деталізованому мезомасштабному прогнозі стану нижнього шару атмосфери з метою екологічного моніторингу повітряного басейну України. Для цих завдань також можна використовувати прогностичну продукцію МЛП.

3.2.2. Мезомасштабне прогнозування як синтез моделі АПС та напівсферної прогностичної моделі

В Одеському державному екологічному університеті (ОДЕКУ) протягом багатьох років проводяться фундаментальні дослідження з фізики атмосферного прикордонного прошарку (АПС) [1,3,4,5,10,11]. Тут розроблено ієрархію гідродинамічних моделей АПС та запропоновано схему параметризації ефектів АПС в оперативній прогностичній моделі Російського гідрометцентру (Москва).

У [3,5,11] викладено теоретичні основи гідродинамічної моделі АПС. В них описана система рівнянь тривимірної нестационарної моделі, що включає середні рівняння гідротермодинаміки, рівняння балансу кінетичної енергії турбулентності та швидкості її дисипації, співвідношення Колмогорова та Смагоринського для вертикального та горизонтального коефіцієнтів турбулентності. Чисельне рішення замкнутої системи за заданих граничних та початкових умов використовується для розрахунків детальних вертикальних профілів метеорологічних величин (вітер,

вологість, температура) та характеристик турбулентності за даними об'єктивного аналізу та прогнозу у вузлах регулярної сітки.

Розроблена вченими ОГЭКУ схема мезомасштабного прогнозування погоди на основі поєднання моделі АПС та напівсферної прогностичної моделі ефективно використовується у Російському гідрометцентрі [10]. Практична реалізація зазначеної схеми виконується у наступній послідовності:

- виконується об'єктивний аналіз та прогноз по повним рівнянням гідротермодинаміки з параметричним урахуванням ефектів прикордонного шару;
- дані об'єктивного аналізу доповнюються спостереженнями локальної мережі для обраної обмеженої області;
- за моделлю АПС здійснюються діагностичні розрахунки характеристик прикордонного шару по обмеженій території;
- за вихідною інформацією прогностичної гідродинамічної моделі та моделі АПС відновлюються прогностичні поля метеорологічних величин та характеристик турбулентності в нижньому шарі атмосфери (до 1,5 км) з високою просторовою роздільною здатністю (по горизонталі $7,5 \times 7,5$ км² та по вертикалі 21 рівень).

Модель атмосферного прикордонного шару ОГЭКУ [3] застосована для розрахунків оперативних гідродинамічних прогнозів у Москві із завчасністю 48ч. Успішність прогнозів вітру, температури, вологості, хмарності та опадів, згідно з рішенням Центральної методичної комісії з гідродинамічних прогнозів Росгідрометцентру, є найвищою серед усіх автоматизованих методик. Тому запропонований метод впроваджено у практику Гідрометцентру Росії [10].

На даний час ОГЕК разом із Гідрометцентром Чорного та Азовського морів (ГМЦ ЧАМ) розробляє метод деталізованого прогнозу швидкості вітру в нижньому шарі атмосфери з використанням даних об'єктивного аналізу Британської метеорологічної служби та описаної вище моделі АПС [3,11].

Таким чином, модель АПС, розроблена в Одеському екологічному університеті, може розглядатися як варіант гідродинамічної інтерполяції прогностичної продукції глобальних та напівсферних моделей з метою отримання детального прогнозу стану нижнього шару атмосфери. Ця інтерполяція має важливе прикладне значення і, зокрема, може бути використана за задачі екологічного моніторингу [5].

3.2.3. Застосування методів математичної статистики у задачі локального прогнозу погоди

Завдання детермінованого прогностичного розрахунку метеорологічних величин в АПС містить нерозв'язні досі труднощі. Точність прогнозів, отриманих з допомогою гідродинамічних моделей, великою мірою залежить від того, наскільки правильно вдалося описати фізичні процеси відповідними рівняннями, і навіть способу їх вирішення. Спрощення, які допускаються при конструюванні відповідних рівнянь, а також при їх вирішенні, призводять до різних помилок прогнозу. Крім того, очевидно, існують і такі процеси, що впливають на погоду, які в даний час неможливо описати за допомогою рівнянь, а про деякі процеси ми взагалі нічого не знаємо і навіть не підозрюємо їх існування [2].

З синоптичної практики відомі випадки, коли при досить вдалому гідродинамічному (фоновому) прогнозі через якісь місцеві особливості локальний прогноз (для даного пункту) виявився не виправданим. За таких умов застосування для прогнозу статистичних методів може бути дуже корисним.

В останні роки в зарубіжній синоптичній практиці при локальному прогнозі явищ та елементів погоди, крім давно застосовуваної концепції «ідеального» прогнозу (PP – perfect prognosis), коли кореляція знаходиться на діагностичному матеріалі, а потім використовується на прогностичних даних, широко впроваджується в оперативну роботу методика MOS (model output statistics). У ній для прогнозу елементів погоди застосовуються статистичні зв'язки, знайдені лише за прогностичними даними. Деякі статистичні прогностичні моделі будуються з

урахуванням спільного використання систем РР і MOS. При цьому вихідні дані напівсферної або регіональної гідродинамічної моделі використовуються для опису очікуваного тла, на якому розвиватимуться процеси, параметри яких розраховуються статистичним шляхом. Таким чином, локальні прогностичні моделі, побудовані на основі емпірико-статистичних зв'язків, дозволяють суттєво покращити прогнозування метеорологічних величин та явищ погоди по невеликих територіях (наприклад, у місті).

На жаль, Гідрометслужба України[32] значно відстає від європейських країн у справі використання сучасних програмно-технологічних ліній автоматизованого мезомасштабного прогнозу погоди. Метеорологічна служба слабо оснащена сучасною комп'ютерною технікою. Хоча роботи деяких науковців України (і, зокрема, ОДЕКУ) у галузі мезомасштабного прогнозування відповідають світовому рівню фундаментальних досліджень, їх результати недостатньо активно використовуються в оперативній практиці.

Настільна книга синоптиків – «Посібник із короткострокових прогнозів погоди» [7] не відображає специфіки роботи метеорологічної служби та не враховує фізико-географічні та кліматичні особливості України. Здійснювані в різних прогностичних підрозділах заходи з автоматизації робочого місця синоптика вимагають науково-методичного супроводу з єдиного центру, щоб уникнути впровадження старих методик і технологій, що погано зарекомендували себе.

3.3. Спрощення моделі короткотермінового прогнозу погоди

На сьогоднішній день було запропоновано низку математичних моделей задач прогнозу погоди та загальної циркуляції атмосфери та чисельних алгоритмів для їх вирішення. Разом з тим необхідно зазначити, що рівняння гідротермодинаміки атмосферних процесів настільки складні, що досі є необхідність розробки більш якісних алгоритмів, здатних з високою точністю описати широкий спектр задач динамічної метеорології та прогнозу погоди. Побудова якісних алгоритмів розв'язання таких завдань тісно пов'язана з проблемою апроксимації рівнянь та

стійкості одержаних різницевих схем, які взагалі є основними проблемами при конструюванні нових чисельних алгоритмів.

Основу всіх моделей атмосфери складають рівняння руху, припливу тепла, нерозривності, переносу вологи та атмосферних домішок, що є математичним виразом законів фізики (законів збереження імпульсу, енергії та маси), а також рівняння стану. Ці рівняння складені для ідеальної атмосфери без урахування турбулентної в'язкості в абсолютній (інерційній) системі координат з початком у центрі землі, віссю z , що збігається з віссю Землі і спрямованої з півдня на північ, а також у відносній системі координат, пов'язаної із Землею, що обертається з кутовою швидкістю ω . У локальній декартовій системі координат вісь x спрямована на схід, вісь y – на північ, вісь z – по місцевій вертикалі; а проекції вектора кутової швидкості обертання Землі ω рівні:

$$\omega_x = 0, \omega_y = \omega * \cos \varphi, \omega_z = \omega * \sin \varphi, \quad (3.1)$$

Де $\omega = \frac{2\pi}{T}$ - абсолютна величина кутової швидкості обертання Землі, $T = 1$ добу, φ - широта місця.

Для програмної реалізації математичної моделі гідротермодинаміки[31] атмосферних процесів приймемо такі додаткові припущення:

- зміна вологості повітря зневажливо мало;
- викид забруднюючих речовин відсутня;
- підведення (відведення) тепла відсутнє (адіабатичні) умови).

З урахуванням прийнятих припущень рівняння моделімають вигляд:

$$\frac{du}{dt} = -\frac{1}{\rho} \frac{\partial p}{\partial x} + l * v - l_1 * w, \quad (3.2)$$

$$\frac{dv}{dt} = -\frac{1}{\rho} \frac{\partial p}{\partial y} + l * u, \quad (3.3)$$

$$\frac{dw}{dt} = -\frac{1}{\rho} \frac{\partial p}{\partial z} + l_1 * u - g, \quad (3.4)$$

$$\frac{\partial \rho}{\partial t} = -\frac{\partial(\rho u)}{\partial x} + \frac{\partial(\rho v)}{\partial y} + \frac{\partial(\rho w)}{\partial z}, \quad (3.5)$$

$$\frac{\partial T}{\partial t} = -\frac{\partial(\tau u)}{\partial x} + \frac{\partial(\tau v)}{\partial y} + \frac{\partial(\tau w)}{\partial z}, \quad (3.6)$$

$$p = \rho * R * T * \mu, \quad (3.7)$$

Де μ = молярна маса повітря, u, v, w – проекції векторів швидкості на осі координат; p, ρ, T – тиск, щільність та температура повітря; $l = 2\omega \sin \varphi$ – параметр Коріоліса, $l_1 = 2\omega \cos \varphi$.

Наведена система рівнянь є замкнутою щодо функцій u, v, w, ρ, T, p . Її слідую доповнити початковими та крайовими умовами. Всі функції залежить від чотирьох змінних (τ, x, y, z) . Початкові умови мають вигляд:

$$\begin{aligned} u(0, x, y, z) &= u_0(x, y, z), \\ v(0, x, y, z) &= v_0(x, y, z), \end{aligned} \quad (3.8)$$

$$w(0, x, y, z) = w_0(x, y, z),$$

$$\rho(0, x, y, z) = \rho_0(x, y, z),$$

$$T(0, x, y, z) = T_0(x, y, z),$$

Граничні умови мають вигляд: $p = \rho * R * T * \mu$,

$$\begin{aligned} u(\tau, 0, y, z) &= u_x(\tau, y, z), \\ u(\tau, 0, y, z) &= u_y(\tau, y, z), \\ u(\tau, 0, y, z) &= u_z(\tau, y, z), \\ u(\tau, 0, y, z) &= v_x(\tau, y, z), \\ u(\tau, 0, y, z) &= v_y(\tau, y, z), \\ u(\tau, 0, y, z) &= v_z(\tau, y, z), \\ u(\tau, 0, y, z) &= w_x(\tau, y, z), \\ u(\tau, 0, y, z) &= w_y(\tau, y, z), \\ u(\tau, 0, y, z) &= w_z(\tau, y, z), \end{aligned} \quad (3.9)$$

$$\begin{aligned}
 u(\tau, 0, y, z) &= p_x(\tau, y, z), \\
 u(\tau, 0, y, z) &= p_y(\tau, y, z), \\
 u(\tau, 0, y, z) &= p_z(\tau, y, z), \\
 u(\tau, 0, y, z) &= T_x(\tau, y, z), \\
 u(\tau, 0, y, z) &= T_y(\tau, y, z), \\
 u(\tau, 0, y, z) &= T_z(\tau, y, z).
 \end{aligned}$$

Система рівнянь є нелінійною системою рівнянь у приватних похідних. У зв'язку з цим рішення в аналітичному вигляді одержати неможливо, і для їх інтегрування застосовуються чисельні методи.

Для вирішення системи рівнянь застосовувався метод сіток, у якому похідні замінюються системою різницевих рівнянь. Область розв'язання задачі є обмеженою частиною площини з нанесеною на неї сіткою. Її можна подати у вигляді квадратної матриці, що складається з осередків, розміром $N \times N$.

Одиницею часу моделі є одна секунда. Відлік часу починається з нуля. Напрямок вітру задається тангенсом кута нахилу до фронту. Сила вітру визначається граничних умовах. Вісь x спрямована на схід, вісь y спрямована на південь. Повітряні маси розглядаються над горизонтальною площиною, щоб виключити з моделі необхідність враховувати рельєф поверхні землі.

Очевидно, має місце масштабність моделі як за поверхневими координатами, так і за часом та відносною різницею температур початкових та граничних умов.

Як демонстраційні приклади були розраховані поля температур у приземному шарі, за початкових умов $T = 20$ °C і граничних умов $T = 30$ °C. На рисунку 3.1 наведено умовну температурну шкалу. З наданої бази даних метеорологічних спостережень розглянемо умови, близькі до моделей, що моделюються.

Наприклад, 13 травня протягом доби у Києві віяв південно-східний вітер швидкістю 2-4 м/с. Виміри температури проводилися в чотирьох точках Києва та

передмість, розташованих приблизно у вершинах квадрата о 7, 13 та 19 годині (таблиця 3.1). Невелике падіння температури до 19 години обумовлено вечірнім зниженням сонячної активності, що не враховувалося в моделі. Очевидно, що реальні дані добре узгоджуються з результатами чисельного експерименту, що свідчить про адекватність запропонованої моделі короткострокового прогнозу температури. Таким чином, навіть дуже спрощена модель, в якій не враховувався вплив рельєфу поверхні, верхніх шарів атмосфери, сусідніх областей дає результати, що досить добре відповідають реальним даним. Облік наведених факторів та скасування припущень, введених у вихідну систему рівнянь, дозволить створити більш точну модель для короткострокового прогнозу не лише температури, а й тиску, вологості, сили та напрямки вітру.

Таблиця 3.1 – Заміри температури у чотирьох точках Києва та передмість

Час, год	7		13		19	
Температура, °С	13.0	12.8	23.0	20.5	22.0	21.5
	12.8	12.8	20.5	20.5	21.5	21.5




Рисунок 3.5—Умовна температурна шкала: а) початковий час; б) час $\tau = 1000$ з; в) момент часу $\tau = 3000$ с

Висновок до 3 розділу

Подальший розвиток методів аналізу та прогнозу погоди в умовах України логічно пов'язаний із розробкою та впровадженням моделі локального гідродинамічного прогнозу погоди. Це визначається принаймні двома обставинами.

По-перше, існуюча ієрархія метеорологічних центрів Всесвітньої служби погоди включає Національні метеорологічні центри (НМЦ), Регіональні метеорологічні центри (РМЦ), та Світові метеорологічні центри (ММЦ). В області прогнозування погоди ММЦ та РМЦ відповідальні за прогнози глобального та напівсферного масштабу на строк до 10 діб. Обов'язком НМЦ є забезпечення споживачів додаткової прогностичної інформацією, одержуваної за допомогою відповідних прогностичних методик на основі прогностичної продукції ММЦ і РМЦ. Інструментом, який може суттєво розширити та наблизити до споживача прогностичну продукцію ММЦ та РМЦ, є моделі локального прогнозу (МЛП).

По-друге, подальше поліпшення якості локальних прогнозів пов'язані з більш точним урахуванням впливу місцевих, мезомасштабних особливостей розвитку атмосферних процесів у режимі. Незважаючи на дуже високий рівень розвитку існуючих глобальних і напівсферних прогностичних систем, необхідні більш високий просторовий дозвіл і ретельніший облік тих конкретних фізичних процесів, які є важливими для даного географічного району (і водночас не є пріоритетними для великомасштабних прогностичних систем). За допомогою МЛП можна отримати детальні короткострокові прогнози погоди.

ЗАГАЛЬНІ ВИСНОВКИ

На сьогоднішній день існують два основних методи наукового передбачення погоди: синоптичний і чисельний (гідродинамічний). Синоптичний метод базується на побудові та аналізі синоптичних карт. Для побудови карт виконується збір МД з різних джерел.

Необхідно також відзначити, що на сьогодні відсутня науково-обґрунтована модель (методика), що дозволяє реалізувати навіть точний середньостроковий прогноз (час, місце, значення МП), яку б теорію (будови Землі, ймовірностей, математичної статистики, ЦГЗ, П і т.д.), з використанням будь-якого математичного апарату (регресійного аналізу, статистичної оцінки, імовірнісного розподілу і т.д.), ґрунтуючись на даних будь-яких спостереженнях (геолого-геофізичних, геохімічних, космічних і т.п.), вона б не використовувала.

Складнощами в реалізації точного прогнозу є дисперсія як самих МД, так і оцінка їх кореляції з МП, що проявляється як статистична неоднозначність і в локалізації місця, і в оцінці інтенсивності зміни, і у визначенні часу прогнозованої події.

Залежно від розв'язуваних завдань, безліч програмного забезпечення, так чи інакше пов'язаного з обробкою і аналізом МД, можна класифікувати за типом вирішуваних завдань на монітори МП, утиліти для конвертації і читання запису МД, обробники МД (аналізатори, програми візуалізації) і власне програми для побудови прогнозів МП.

Аналіз програмного забезпечення, в частині прогнозування метеорологічних параметрів, на основі нейромережевого аналізу дозволяє зробити наступний висновок:

– всі програми оперують даними від метеорологічних станцій (наземного, повітряного та космічного базування);

- всі розглянуті програми використовують певну модель оцінки, побудовану на відмінностях метеорологічних даних досліджуваних періодів від ретроспективних;

- всі розглянуті програми побудовано з використанням того чи іншого математичного апарату, що дозволяє реалізувати аналіз відмінностей порівнюваних періодів з використанням синтетичної градації терезів того чи іншого параметра або їх сукупності;

- у розглянутих програмах прогнозна оцінка будується методом порівняння розрахованої величини або комплексної оцінки можливої події, за критерієм перевищення експериментально встановленого порогу мул.

Оснoву оперативного прогнозування погоди слід оновити та перевизначити. Завдяки своїй незамінності чисельна модель для системи Землі, безумовно, стане центром оперативного прогнозування в наступній безперебійній ері. Постійні дослідження та розробки є єдиним способом подолати неточність і неповноту чисельних моделей. Властивості чисельних моделей Triple-In підкреслюють дослідницькі атрибути загальної метеорологічної діяльності.

Як модель аналізу даних мною був досліджений алгоритм векторного кодування – модель Кахонена. Ця модель реалізує топологічне відображення (рисунок 2.2), яке оптимально розміщує фіксовану кількість векторів (тобто кодових слів) у вхідний простір вищої розмірності i , таким чином, полегшує аналіз даних.

Для навчання мережі був вибраний алгоритм SOM. Сутність алгоритму SOM[30], запропонованого Кохоненом, полягає у простому геометричному обчисленні властивостей Хеббоподібного правила навчання та латеральних взаємодій.

У процесі виконання описаного алгоритму було отримано карту, показану на рисунку 2.14. Даний алгоритм аналізу МП на основі самоорганізовані карти є нейронною мережею, побудованою на одно- або двовимірній решітці нейронів для отримання важливих ознак, що містяться у вхідному просторі. Таким чином, можна

отримати структурне подання вхідних даних, використовуючи як прототипи вектори ваги нейронів. Алгоритм SOM має нейробіологічне підґрунтя. Він об'єднав у собі всі основні механізми, властиві самоорганізації: конкуренцію, кооперацію та самопосилення. Таким чином, його можна розглядати як універсальний, незважаючи на неповний розвиток моделі, що описує виникнення явища колективного порядку в складних системах, що починаються з повного безладдя.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Тарнопольский А.Г., Шнайдман В.А. Моделирование геофизического пограничного слоя// Доповіді НАН України. – 1993. – № 9. – С. 105-112.
2. Русин И.Н. Современные методы метеорологических прогнозов. – Л.: ЛГМИ, 1987. – 96 с.
3. Беркович Л.В., Тарнопольский А.Г., Шнайдман В.А. Гидродинамическая модель атмосферного и океанического пограничных слоев// Метеорология и гидрология. – 1997. – № 7. – С. 40–52
4. Shnaidman V.A., Tarnopolsky A.G., Berkovich L.V. The method of atmospheric boundary layer structure prediction// Research activities in atmospheric and oceanic modelling. – 1997. – Rep. No. 25, WMO/TD – No. 792. – P. 5.38–5.39.
5. Бенгтсон Л. Прогнозы на средние сроки в Европейском центре прогнозов погоды на средние сроки (ЕЦППС). В кн.: Динамика погоды. – Л.: Гидрометеиздат, 1988. – С. 18–64.
6. Степаненко С.Н. Математическое моделирование мезомасштабных процессов и явлений в атмосфере. – Одесса, Бахва, 2001, 290 с.
7. Руководство по краткосрочным прогнозам погоды. Ч. 1. – Л.: Гидрометеиздат, 1986. – 703 с.
8. Степаненко С.Н. Динамика турбулентно-циркуляционных и диффузионных процессов в нижнем слое атмосферы над Украиной. – Одесса, Маяк, 1998, 286 с.
9. Shnaidman V.A., Tarnopolsky A.G., Berkovich L.V. The analysis and prediction of ABL parameters with the operative meteorological information// Research activities in atmospheric and oceanic modelling. – 1998. – Rep. No. 27, WMO/TD – No. 865. – P. 5.54–5.55.
10. Белов П.Н., Борисенков Е.П., Панин Б.Д. Численные методы прогноза погоды. – Л.: Гидрометеиздат, 1989. – 376 с.

11. Беркович Л.В., Тарнопольский А.Г., Шнайдман В.А. Опыт восстановления внутренней структуры атмосферного пограничного слоя по оперативной метеорологической информации// Метеорология и гидрология. – 1998. – № 7. – С 31–42.
12. Филиппович Ю. Н., Филиппович А. Ю. Системы искусственного интеллекта. М.: МГУП, 2009.
13. IOS Press Content Library. Intelligent Data Analysis - Volume 5, issue 1. – 2021.
14. Станкевич Л.А. Интеллектуальные системы и технологии. Учебник и практикум для бакалавриата и магистратуры. – 2016. С. 64 – 81.
15. Саймон Хайкин. Нейронные сети: полный курс, 2-е издание. – 2008 –.
16. Ivan Gavrilyuk, Volodymyr Makarov, Vitalii Vasylyk. Exponentially Convergent Algorithms for Abstract Differential Equations.
17. Рутковская М., Плинский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. М
18. Сайт Высшей аттестационной комиссии, Катцов В.М. Исследование динамики климата высоких широт с помощью моделей общейциркуляции атмосферы и океана: автореф. [электронный ресурс]. Режим доступа: http://vak.ed.gov.ru/announcements/fiz_mat/KattsovVM.pdf.
19. Дымников В.П. Моделирование климата и его изменений // Глобальные изменения природной среды и климата: избр. науч. тр. М., 1997. С. 21–231.
20. Самарский А.А. Теория разностных схем. М.: Наука, 1977
21. Бахвалов Н.С., Жидков Н.П., Кобельков Г.М. Численные методы. Изд. 2-е. М.; СПб.: Физматлит, 2001.
22. Круглов В. В., Дли М. И., Голунов Р. Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001.
23. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2004.

24. Веб-застосунок [Електронний ресурс]. – Режим доступу: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3690007/>
25. Владимир Гордин. Математика, компьютер, прогноз погоды и другие сценарии математической физики. 2018 г.
26. Иващенко А.Б. Анализ моделей прогноза погоды: автореф. [электронный ресурс]. Режим доступа: <http://masters.donntu.edu.ua/2006/fvti/ivaschenko/diss/index.htm>.
27. Александр Кириченко. Основы теории искусственных нейронных сетей. 2021 г.
28. Николенко Сергей, Кадурич Артур, Архангельская Екатерина. Глубокое обучение. "Издательский дом ""Питер""", 2017 г
29. Саймон Хайкин. Нейронные сети: полный курс, 2-е издание. Издательский дом Вильямс, 2008
30. Bill Smyth. Computing patterns in strings. 2006
31. Виктория Наац, Игорь Наац. Математические модели и численные методы в задачах экологического мониторинга атмосферы. 2018 г.
32. Ecology and natural resources of Ukraine, Том 3. Vyd-vo "Novyї svit", 2006
33. Referativnyї zhurnal: Geografiia, 2003
34. Sanja Bauk, Stojče Dimov Ilčev. The 1st International Conference on Maritime Education and Development: ICMED.