

І. М. Ганношина

Державний університет інфраструктури та технологій, Київ, Україна

## РОЗРОБКА МОДЕЛІ ГЛИБОКОЇ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ОЦІНКИ СТАНУ МОРЯ НА ОСНОВІ РУХУ СУДНА

**Анотація.** Метою роботи є розробка моделі глибокої нейронної мережі для оцінки стану моря на основі руху судна з використанням щільно пов'язаних згорткових нейронних мереж для підвищення безпеки та ефективності, точності, залежності та динаміки оцінки стану моря для вирішення як завдань класифікації, так і завдань регресії. В результаті побудови моделі глибокої нейронної мережі оцінки стану моря на основі руху судна були отримані такі результати: спочатку була розроблена архітектура мережі на основі щільно пов'язаних згорткових нейронних мереж (DenseNet) з унікальним поєднанням модифікацій і шарів. Така архітектура дає можливість ефективно враховувати залежності і динаміку руху судна, що призводить до більш точної оцінки стану моря. По-друге, мережа була навчена підготовленим даним руху судна за допомогою оптимізаторів і функцій втрат, підібраних відповідно до завдання оцінки стану моря. Тренувальний процес містив налаштування гіперпараметрів, оптимізацію ваг та оцінку продуктивності моделі за тестовими даними. По-третє, модель оцінювалася за даними випробувань за допомогою відповідних метрик у залежності від конкретного завдання оцінки стану моря. Наприклад, для задачі класифікації використовувалася матриця точності і помилок, а для задачі регресії – середня абсолютна похибка (MAE) і середня квадратична похибка кореня (MSE). Результати побудови моделі глибокої нейронної мережі для оцінки стану моря на основі руху судна підтверджують її ефективність і значимість для мети дослідження. Застосування такої моделі важливо саме в контексті оцінки стану моря. Висока точність оцінки допомагає приймати більш достовірні рішення і прогнозувати можливі зміни відповідно до морських умов, що виникають на даний час руху судна. Врахування залежностей і динаміки руху судна дозволяє моделювати й адаптуватися до умов, що змінюються, що підвищує його технологічність та ефективність. Використання такої моделі сприяє підвищенню безпеки та ефективності морських операцій, оптимізації використання ресурсів і запобігання можливим аваріям. Таким чином, модель глибокої нейронної мережі, розроблена для оцінки стану моря на основі руху судна, є ефективним інструментом у сфері безпеки та ефективності судноплавства. Її використання сприяє більш точним прогнозам і прийняттю обґрунтованих рішень, що важливо для морських операцій і забезпечення безпеки судноплавства в цілому.

**Ключові слова:** глибока нейронна мережа, модель мережі, оцінка стану моря, рух судна, щільно пов'язана згорткова нейронна мережа.

### Вступ

**Постановка проблеми.** Оцінка стану моря є важливою і актуальною проблемою в області морського судноплавства і навігації. Стан моря охоплює широкий спектр фізичних параметрів і явищ, таких як хвилі, вітер, течії, лід та інші фактори, що впливають на безпеку та ефективність морських перевезень. Точна та достовірна оцінка стану моря має вирішальне значення для прийняття обґрунтованих рішень, забезпечення безпеки судноплавства та оптимізації операцій на морі.

Однак оцінити стан моря складно через кілька факторів. По-перше, морське середовище – це динамічне і мінливе середовище, що вимагає врахування часових і просторових коливань параметрів. По-друге, більшість існуючих методів оцінки стану моря засновані на фізичних моделях, які можуть бути неповними або приблизними. Крім того, обробка та аналіз великих обсягів різномірних даних від різних датчиків є складним завданням. У світлі цих складнощів використання глибоких нейронних мереж представляє перспективний напрямок досліджень для вирішення проблеми оцінки стану моря.

Використання глибоких нейронних мереж в області оцінки стану моря і руху судна має ряд переваг:

1. Обробка складних і неструктурованих даних: глибокі нейронні мережі дозволяють ефективно працювати з великими обсягами даних, включаючи зображення, радіолокаційні вимірювання і мультисенсорні дані. Це дозволяє враховувати різні фактори і

особливості, пов'язані з оцінкою стану моря і рухом судна.

2. Автоматизація і точність: Використання глибоких нейронних мереж дозволяє автоматизувати процес оцінки стану моря і руху судна, що знижує людський фактор і підвищує точність результатів. Глибокі нейронні мережі можуть виявляти складні закономірності і залежності в даних, роблячи оцінку більш надійною і точною.

3. Виявлення та класифікація об'єктів: глибокі нейронні мережі можуть ефективно виявляти та класифікувати різні об'єкти в морському середовищі, включаючи кораблі, хвилі, лід та інші елементи. Це може бути корисним для навігації, безпеки, охорони навколишнього середовища та інших аспектів морської техніки.

4. Покращення прогнозування та прийняття рішень: глибокі нейронні мережі можуть аналізувати історичні дані та виявляти приховані зв'язки, що може покращити здатність прогнозувати та приймати рішення щодо стану моря та руху судна. Це може бути корисно для морських операцій, планування маршрутів, прогнозування погоди та інших додатків.

5. Гнучкість та адаптивність: глибокі нейронні мережі мають гнучкість та адаптивність для застосування в різних середовищах та з різними типами даних. Їх можна налаштувати і навчити вирішувати конкретні завдання, що робить їх потужним інструментом в оцінці стану моря і руху судна.

З огляду на ці переваги, використання глибоких нейронних мереж дозволяє значно підвищити ефек-

тивність і точність оцінки стану моря і руху судна. Однак варто зазначити, що для навчання і настройки моделей потрібна достатня кількість даних, а також правильний вибір архітектури і методів під конкретне завдання (чи то завдання класифікації, чи завдання регресії).

Використання глибоких нейронних мереж в області оцінки стану моря продовжує активно розвиватися і пропонує кілька перспективних напрямків, наприклад:

1. Мультимодальна інтеграція даних: розробка методів інтеграції різних типів даних, таких як радіолокаційні зображення, оптичні зображення, мультисенсорні дані та інші, в єдину глибоку нейронну мережу. Це дасть можливість більш повно врахувати різні аспекти і особливості морського середовища при оцінці стану і руху судна.

2. Автоматичне виявлення та класифікація різних об'єктів у морському середовищі, таких як судна, хвилі, лід, риба та інші. Це може сприяти безпеці, навігації та охороні навколишнього середовища.

3. Покращене прогнозування та прийняття рішень: розробка методів глибинного навчання для прогнозування морських умов та руху суден на основі історичних даних, включаючи використання рекурентних нейронних мереж та моделей довгої короткострокової пам'яті (LSTM). Це може допомогти операторам приймати більш обґрунтовані рішення та оптимізувати офшорні операції.

4. Навчання на розріджених даних: розробка методів глибокого навчання, здатних ефективно працювати з обмеженими та розрідженими даними, що може бути важливим у контексті оцінки стану моря, де дані можуть бути недоступними або мати обмежену інформацію.

5. Аналіз часових рядів: розширення використання глибоких нейронних мереж для аналізу даних часових рядів, пов'язаних з оцінкою стану моря, таких як параметри руху суден, погодні умови, припливи та інші фактори. Це може допомогти в більш точному моделюванні та прогнозуванні стану морського середовища.

6. Навчання з підкріпленням: застосування методів навчання з підкріпленням у контексті оцінки стану моря, щоб моделі могли вчитися на зворотному зв'язку, який вони отримують, і реагувати на зміни в навколишньому середовищі та умовах.

Ці напрямки розвитку дозволять розширити використання глибоких нейронних мереж в області оцінки стану моря і руху судна, підвищити точність, надійність і ефективність таких систем. Однак вони також вимагають подальших досліджень, розробки та валідації моделей на різних наборах даних та умовах експлуатації. Одним з найбільш актуальних напрямків в даній предметній області є використання високоефективних щільно зв'язаних згорткових нейронних мереж.

**Аналіз останніх досліджень і публікацій.** Достить значна кількість робіт у теперішній час присвячена вивченню проблем використання глибинного навчання для оцінки стану моря [1 - 8].

Так, у рамках спільного дослідницького проекту RetroLadung розробляються вагово-оптимізовані

комірки з інтегрованими датчиками руху і системами підтримки прийняття рішень на основі даних (DSS). Однією з основних функцій DSS є оцінка стану моря на основі даних вимірювань з датчиків прискорення. Для виконання цього завдання створюється згорткова нейронна мережа (CNN), яка навчається на даних моделювання. У статті [1] представлені початкові етапи розвитку мережі, в якій розглядаються унімодальні морські хвилі з описом спектрів JONSWAP. При цьому виключається швидкість руху вперед. Інститут гідродинаміки і теорії суден (FDS) проводить випробування в модельному басейні, а отримані результати використовуються для перевірки прогнозів оцінки стану моря (SSE).

У статті [2] пропонується новий підхід до оцінки стану моря, який отримав назву SpectralNet. Він заснований на використанні спектрограм і глибокому навчанні. Дані руху космічного апарату перетворюються в спектрограми за допомогою короткочасного перетворення Фур'є. Потім спектрограми об'єднуються в нові зображення, які подаються в двовимірну згортувальну нейронну мережу для класифікації стану моря. Результати експериментів показують, що запропонований підхід забезпечує вищу точність класифікації, ніж інші методи, застосовані до необроблених даних часових рядів. Крім того, точність класифікації збільшується зі збільшенням кількості комбінованих датчиків. Аналіз чутливості показує, що масштабне співвідношення зображень має значний вплив на точність класифікації.

Для класифікації стану моря використовуються різні методи, але вони вимагають значних капітальних і експлуатаційних витрат, а також великих обчислювальних потужностей. У статті [3] запропонована нова модель класифікації стану моря на основі глибокого навчання з використанням зображень моря у візуальному діапазоні. Створено та протестовано набір даних зображень стану моря, що містить 100 800 зображень за допомогою сучасних класифікаційних моделей з глибоке навчання. Показано, що модель на основі змін у початковому блоці моделі GoogLeNet досягає точності класифікації 8, що перевищує точність інших моделей. Крім того, запропонована модель вимагає менше часу на навчання і має конкурентну класифікаційну швидкість.

В роботі [4] запропонований гібридний підхід до оцінки спектра хвиль на основі аналогії з хвильовим буєм. Використовується поєднання машинного навчання і фізичного методу з урахуванням наявних передавальних функцій. Отримано непараметричну оцінку спектра спрямованих хвиль за допомогою згорткової нейронної мережі. Розроблений метод успішно застосовується на даних, отриманих з контейнеровоза протягом двох років. Результати показують значне поліпшення в порівнянні з Первинна оцінка без обмежень.

У статті [5] також розглядається підхід, заснований на машинному навчанні, до оцінки стану моря за аналогією з хвильовим буєм. Використовуючи дані датчиків судна, був зроблений прогноз стану моря. У статті порівнюються моделі в часовій і частотній областях з урахуванням точності, надійності та обчислю-

вальних витрат. Глибокі нейронні мережі навчалися з урахуванням впливу різних параметрів, таких як частотна дискретизація і довжина вибірки. Початкова архітектура, адаптована під послідовні дані, показала кращу продуктивність. Використовувалося багатозадачне навчання, що призвело до кращої здатності до узагальнення та меншої невизначеності. В цілому частотно-доміненний метод демонструє більш високу продуктивність і менші витрати на обчислювальне навчання.

Приклади статей, пов'язаних з використанням архітектури DenseNet в різних завданнях [9 - 11]:

1. Оригінальна стаття [9], в якій архітектура DenseNet була запропонована вперше, представлений докладний опис архітектури і результати експериментів на декількох наборах даних комп'ютерного зору.

2. Робота [10] представляє підхід на основі глибокого навчання для оцінки стану моря. Запропонована в роботі модель SNET використовує тісно пов'язані згорткові нейронні мережі, модулі уваги каналів і модуль уваги функції для оцінки висоти і напрямку хвиль, а також даних про рух судна. Метод показує конкурентні результати в порівнянні з іншими підходами і демонструє ефективність на реальних наборах даних.

Таким чином, дослідженням по використанню високоефективних щільно зв'язаних згорткових нейронних мереж для вирішення завдань оцінки стану моря на основі руху судна одночасно с точки зору завдань класифікації та регресії в даний час розглянуто не в повному обсязі.

**Метою статті** є розробка моделі глибокої нейронної мережі для оцінки стану моря на основі руху судна з використанням щільно пов'язаних згорткових нейронних мереж для підвищення безпеки та ефективності, точності, залежності та динаміки оцінки стану моря для вирішення як завдань класифікації, так і завдань регресії.

## Викладення основного матеріалу дослідження

У даній статті представлена нова архітектура мережі, запропонована авторами, заснована на щільно пов'язаних згорткових нейронних мережах (DenseNet), спеціально адаптованих для аналізу даних руху суден для оцінки стану моря для вирішення як завдань класифікації, так і завдань регресії.

Методологія розробки цієї архітектури включає такі етапи (рис. 1):

1. Збір даних про рух судна, тобто інформації про різні параметри руху судна, такі як швидкість, кут курсу, прискорення, характеристики хвиль і т. д.

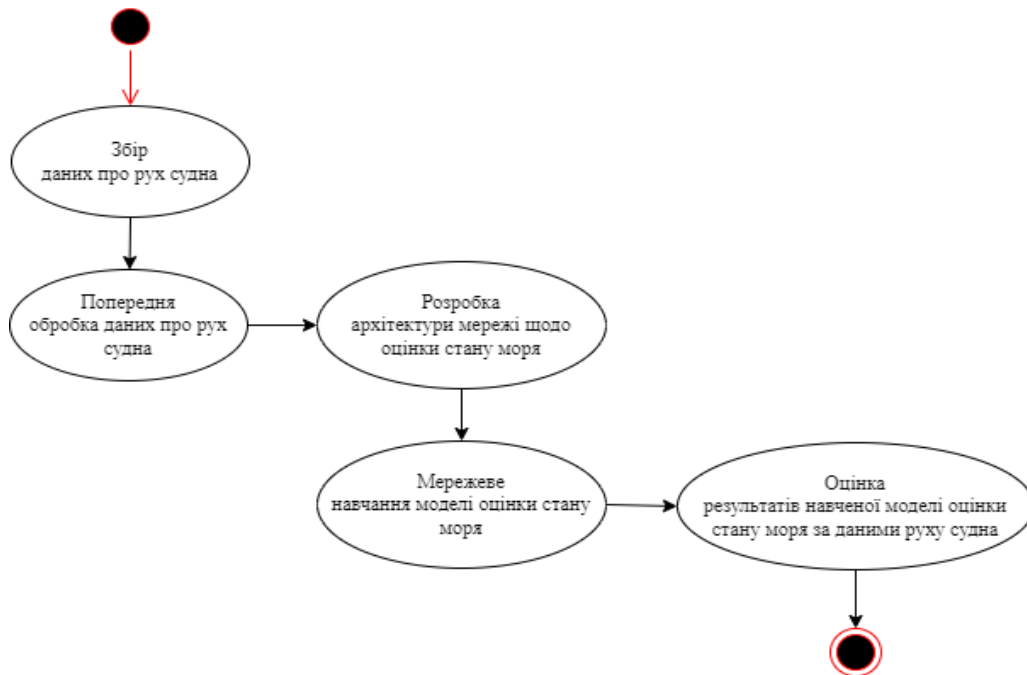
2. Попередня обробка даних про рух судна. На цьому етапі дані відфільтровані, стандартизовані або доведені до відповідного формату для подачі на вхід нейронної мережі.

3. Розробка архітектури мережі щодо оцінки стану моря. Запропоновано нову мережеву архітектуру, засновану на щільно пов'язаних згорткових нейронних мережах (DenseNet), з додаванням спеціальних шарів та модифікацій для кращого задоволення вимог щодо оцінки стану моря.

4. Мережеве навчання моделі оцінки стану моря. Архітектура мережі навчається на підготовлених даних про рух судна, використовуючи оптимізатори і функції втрат, підібрані відповідно до завдання оцінки стану моря.

5. Оцінка результатів навченої моделі оцінки стану моря за даними руху судна. Ефективність навченої моделі оцінюється за даними тестів. Метрики оцінки містять середню квадратичну похибку (MSE), коефіцієнт детермінації  $R^2$  тощо.

Збір даних про рух суден є важливою частиною процесу оцінки стану моря за допомогою глибоких нейронних мереж.



**Рис. 1.** Узагальнена структура методології розробки архітектури глибокої нейронної мережі для оцінки стану моря на основі руху судна

Дані про параметри руху судна (швидкість, кут курсу, прискорення, характеристики хвиль), є ключовими для аналізу і моделювання морського середовища

$$D = \langle S, H, A, X \rangle, \quad (1)$$

де  $S$  – швидкість. Вимірювання швидкості судна є одним з основних параметрів руху. Для цього можуть використовуватися різні датчики і системи, такі як Acoustic Doppler Log (ADL), GPS (Global Positioning System), Inertial Measurement Unit (IMU) та ін. Ці датчики здатні визначати швидкість судна в різних напрямках і відстежувати її зміни в часі;

$H$  – кут курсу судна, який визначає напрямок, в якому воно рухається. Дані про кут курсу судна можна отримати за допомогою компасів, гіроскопів або GPS. Його знання важливо для визначення шляху і маршруту судна, а також для прогнозування можливих змін напрямку руху;

$A$  – прискорення. Вимірювання прискорення судна дозволяє визначити зміну швидкості в часі. Для цього можуть використовуватися бустери або IMU, які можуть виявляти зміни лінійного і кутового прискорення. Дані прискорення допомагають оцінити динаміку;

$X$  – характеристики хвиль, які визначаються відповідно до вимог, що визначені в роботах [7, 8, 10].

Попередня обробка даних відіграє важливу роль у використанні щільно пов'язаних згорткових нейронних мереж для оцінки стану моря. Правильна обробка даних перед подачею на мережевий вхід дозволяє підвищити ефективність моделі і якість результатів. Алгоритм, який включає методи та підходи до попередньої обробки даних у цьому контексті, наведено на рис. 2:

1. Фільтрація даних і усунення шуму дозволяє отримати чисті та надійні вимірювання. Це може включати застосування фільтрів низьких або високих частот, а також таких методів, як фільтрація ковзного

середнього або медіана. Мета полягає в усуненні аномалій і шумів, які можуть спотворювати дані і впливати на точність оцінки стану моря.

2. Нормалізація і стандартизація. Після фільтрації дані можуть бути нормалізовані або стандартизовані, щоб привести їх до певного діапазону значень або середнього значення. Це дозволяє встановити однаковий масштаб даних і запобігає проблемам з різними амплітудами або варіацією даних.

3. Вирівнювання і сегментація. Залежно від призначення і завдання моделювання можна застосувати методи вирівнювання і сегментації даних. Наприклад, часові ряди даних про рух суден можуть бути вирівняні в часі або сегментовані на фіксовану тривалість, щоб забезпечити однорідність даних для навчання мережі.

4. Збільшення даних. Методи збільшення можуть бути застосовані для збільшення різноманітності та обсягу даних. Це може включати горизонтальне або вертикальне відображення даних, додавання випадкових шумів або спотворень, а також генерацію штучних даних на основі існуючих даних. Збільшення допомагає підвищити надійність моделі та здатність до узагальнення, коли недостатньо кількості та різноманітності даних.

5. Поділ на навчальні та тестові зразки. Для оцінки працездатності моделі дані можна розділити на навчальні та тестові вибірки. Навчальна вибірка використовується для навчання мережі, в той час як тестова вибірка дозволяє оцінити її точність і здатність узагальнювати на нові дані.

6. Балансування класів. Якщо дані мають дисбаланс класів (наприклад, різні стани моря можуть бути представлені нерівномірно), може знадобитися збалансувати класи, щоб запобігти зміщенню моделі в бік більш поширених класів. Цього можна досягти шляхом підвибірки, передискретизації або застосування зважування класу в навчанні.




Рис. 2. Узагальнена структура алгоритму попередньої обробки даних глибокої нейронної мережі для оцінки стану моря на основі руху судна

При розробці мережевої архітектури оцінки стану моря з використанням щільно пов'язаних згорткових нейронних мереж (DenseNet) автори можуть запропонувати нові модифікації або спеціальні шари для кращого задоволення вимог даної конкретної задачі. Розглянемо можливі модифікації, які можна внести в архітектуру мережі:

1. Додаткові згорткові шари. Додаткові згорткові шари можуть бути додані для поліпшення здатності мережі витягувати функції з даних про рух суден. Це допоможе покращити здатність моделі виявляти та виділяти важливі закономірності та закономірності в даних.

2. Об'єднання шарів. Включення шарів об'єднання може допомогти зменшити розмірність даних і стиснути інформацію, зберігаючи важливі характеристики. Це дозволяє підвищити ефективність і здатність узагальнення моделі, а також зменшити кількість параметрів та обчислювальну складність.

3. Щільне з'єднання шарів. Однією з особливостей DenseNet є щільне з'єднання шарів, де кожен шар має прямі зв'язки з кожним наступним шаром. Це сприяє кращій передачі інформації між шарами і покращує потік градієнтів при зворотному поширенні помилки. В архітектурі мережі оцінки стану моря цю властивість можна посилити додаванням додаткових прямих зв'язків або збільшенням щільності зв'язків між шарами.

4. Рекурентні шари. У разі, коли дані про рух судна є часовим рядом, рекурентні шари, такі як шари LSTM (Long Short-Term Memory), можуть бути включені в архітектуру мережі. Це дозволить моделі враховувати залежності і динаміку в даних, що може бути важливо для точної оцінки стану моря.

5. Адаптивна активація і нормалізація шарів. Увімкнення шарів адаптивної активації, таких як шари SELU (масштабовані експоненційні лінійні одиниці) або Mish, а також нормалізація шарів, таких як шари пакетної нормалізації, можуть допомогти прискорити навчання та покращити стабільність мережі. Це може бути особливо корисно при роботі з великими і складними наборами даних.

Унікальне поєднання цих модифікацій і шарів в архітектурі мережі дозволить поліпшити здатність моделі оцінювати стан моря на основі даних про рух суден. Таким чином, конкретні комбінації модифікацій і шарів в архітектурі мережі можуть змінюватися в залежності від конкретного завдання оцінки стану моря і характеристик наявних даних. Розглянемо варіант можливої унікальної комбінації модифікацій і шарів, які можна використовувати в архітектурі мережі для оцінки стану моря в загальному сенсі:

1. Рівень вхідних даних. Архітектура мережі може починатися з вхідного шару, який приймає дані про рух судна, такі як швидкість, кут курсу, прискорення, характеристики хвиль тощо. Математично вхідний шар можна представити таким чином:

$$I = [x_1, x_2, \dots, x_n] \quad (2)$$

де  $I$  – вектор введення (вхідний шар);

$x_1, x_2, \dots, x_n$  – векторні елементи, що представляють значення параметрів руху судна.

Таким чином, цей стандартний підхід описує рівень вхідних даних як вектор  $n$  елементів, де кожен елемент  $x_i$  являє собою один з параметрів руху судна, таких як швидкість, кут курсу, прискорення, характеристики хвиль.

2. Згорткові шари. Кілька згорткових шарів можуть бути використані для вилучення особливостей з входів руху судна. Кожен згортковий шар може мати різні фільтри та ядра згортки для виділення різних аспектів даних. Представимо згорткові шари в даному контексті наступним чином: нехай буде  $k$ -ий згортковий шар, позначимо його як  $C_k$ . Для кожного згорткового шару  $C_k$ , його вихід (активації)  $h_k$  розраховуються шляхом застосування операції згортки до попереднього шару або вхідних даних:

$$h_k = f(W_k * h_{k-1} + b_k), \quad (3)$$

де  $h_k$  – активація  $k$ -го згорткового шару;  $f(x)$  – функція активації, застосована до кожного шару;  $W_k$  – матриця ваг (згорткові ядра) для  $k$ -го згорткового шару;  $b_k$  – вектор зміщення (bias) для  $k$ -го згорткового шару;  $h_{k-1}$  – активації попереднього шару (входи або активації попереднього згорткового шару).

Операція згортки  $W_k * h_{k-1}$  являє собою підсумовування добутків фільтруючих елементів з відповідними вхідними даними елементів (або активацій попереднього шару). Потім застосовується функція активації  $f(x)$ , щоб отримати остаточні активації  $h_k$  цього згорткового шару.

Таким чином, згорткові шари дозволяють витягти і виділити з вхідних даних про рух судна, що важливо для оцінки стану моря.

3. Об'єднувальний шар. Після згорткових шарів можна додати шар об'єднання, щоб зменшити розмірність даних і зберегти важливі особливості. Наприклад, шар MaxPooling можна використовувати для вибору найбільш значущих значень у кожному вікні даних. Уявімо об'єднувальний шар в даному контексті таким чином: нехай буде  $k$ -ий об'єднуючий шар, позначимо його як  $P_k$ .

Для кожного шару пулу  $P_k$  вихід  $h_k$  обчислюються шляхом застосування операції пулу до попереднього згорткового шару або активацій

$$h_k = Pool(W_k * h_{k-1} + b_k) \quad (4)$$

де  $h_k$  – вихід (активації)  $k$ -го шару об'єднання; Pool – операція об'єднання, яка може бути, наприклад, операцією MaxPooling або операцією середнього об'єднання (AveragePooling);  $W_k$  – масштабна матриця (якщо використовується) для  $k$ -го шару об'єднання;  $b_k$  – вектор зміщення (зміщення) для  $k$ -го шару об'єднання;  $h_{k-1}$  – входи або активації попереднього згорткового шару.

Операція об'єднання дає змогу зменшити розмірність даних, вибравши найбільш значущі значення у вікні даних.

4. Щільне з'єднання шарів. Включення принципу щільного з'єднання шарів, характерного для DenseNet, дозволяє створювати прямі зв'язки між кожним поточним шаром і кожним наступним шаром. Це покращує потік градієнтів і полегшує обмін інформацією між шарами. Уявімо принцип щільного

з'єднання шарів в даному контексті таким чином: дайте  $K$  шари в архітектурі DenseNet позначимо як  $H_1, H_2, \dots, H_K$ . Кожен шар  $H_k$  отримує вхідні дані не тільки з попереднього шару  $H_{k-1}$ , але також з усіх попередніх шарів

$$H_k = [H_1, H_2, \dots, H_{k-1}] \oplus F(W_k * H_{k-1} + b_k) \quad (5)$$

де  $H_k$  – активації (вихід)  $k$ -го шару DenseNet;  $[H_1, H_2, \dots, H_{k-1}]$  – об'єднання активацій всіх попередніх шарів;  $\oplus$  – операція конкатенації;  $F(x)$  – функція активації, застосована до кожного шару;  $W_k$  – матриця ваг для  $k$ -го шару;  $b_k$  – вектор зміщення (зміщення) для  $k$ -го шару,  $H_{k-1}$  – активація попереднього шару (входи  $k$ -го шару).

Таким чином, принцип щільного з'єднання дозволяє кожному шару отримувати інформацію з усіх попередніх шарів, що сприяє більш повній передачі і використанню інформації всередині мережі.

5. Рекурентні шари. Якщо дані про рух суден представлені у вигляді часового ряду, можливо додати поточні шари, такі як шари LSTM (довга короткочасна пам'ять) або GRU (закрита рекурентна одиниця). Ці шари дозволяють враховувати залежності та динаміку у ваших даних. Шар закритого рекурентного блоку в цьому контексті діє таким чином: маємо  $k$ -ий шар GRU, позначимо його як  $GRU_k$ . Для кожного шару  $GRU_k$ , його вихід  $h_k$  обчислюються шляхом оновлення статусу (update gate)  $z_k$ , скинути стан (reset gate)  $r_k$  та обчислити новий латентний стан  $h_k$

$$z_k = \sigma(W_{z_k} * [h_{k-1}, x] + b_{z_k} r_k, \quad (6)$$

де  $\sigma$  – функція активації сигмовидної сигмоїди (наприклад, logistic sigmoid).

Операція оновлення статусу  $z_k$  контролює, яку інформацію слід оновлювати, а операція скидання стану  $r_k$  визначає, яку інформацію слід забути з попереднього стану  $h_{k-1}$ . Новий прихований стан  $h_k$  розраховується на основі оновленого стану і нових входів.

Таким чином, шар Gated Recurrent Unit (GRU) дозволяє моделювати залежності і динаміку в часових рядах даних про рух судна, що може стати в нагоді в завданні оцінки стану моря. GRU надає можливість запам'ятовувати інформацію на основі станів, дозволяючи враховувати контекст та історію в часових даних для більш точної оцінки морських умов.

6. Адаптивна активація та нормалізація шарів: В архітектурі мережі адаптивні рівні активації, такі як SELU (масштабовані експоненційні лінійні одиниці) або Mish, можуть бути використані для забезпечення більш плавної активації та більш стабільного навчання. Можна також ввімкнути шари нормалізації, такі як шари пакетної нормалізації, для стабілізації та нормалізації виводу шарів.

При навчанні мережі важливо вибрати оптимізатор, який буде мінімізувати функцію втрат й оновлювати ваги мережі на основі градієнтного спуску. Різні оптимізатори, такі як стохастичний градієнтний спуск (SGD), Adam або RMSprop, можуть використовуватися в залежності від специфіки завдання і вимог до навчання.

Також важливо вибрати відповідну функцію втрат, яка відображає мету завдання оцінки стану моря.

Наприклад, для задачі регресії функцією втрат може бути стандартна помилка (MSE), яка вимірює стандартне відхилення між прогнозованими та фактичними значеннями. Для задачі класифікації можна використовувати категоріальну перехресну ентропію, яка вимірює різницю між прогнозованим та істинним класами.

Весь процес навчання мережі складається з ітеративної оптимізації ваг за допомогою обраного оптимізатора і функції втрат. Мережа запускає навчальні дані через свої шари, порівнює прогнози з істинними значеннями та обчислює значення функції втрат. Потім градієнти функції втрат обчислюються і використовуються оптимізатором для оновлення ваги мережі. Цей процес повторюється протягом декількох епох до тих пір, поки не буде досягнуто конвергенції або певного умови зупинки.

Таким способом навчається архітектура мережі на основі заздалегідь підготовлених даних про рух судна, а підбір оптимізаторів і функцій втрат здійснюється відповідно до мети оцінки стану моря. Це дозволяє мережі ефективно витягувати інформацію з даних і вчитися на зворотному поширенні помилки, щоб досягти оптимальних показників при оцінці стану моря. Для оцінки моделі, яка оцінює стан моря на основі руху судна, особливо корисними можуть бути такі показники:

#### 1. Класифікація:

– точність: оцінка частки правильно класифікованих прикладів із загальної кількості прикладів. Ця метрика показує загальну здатність моделі правильно класифікувати різні морські умови;

– матриця точності і помилок: надає інформацію про кількість правильних і неправильних класифікацій для кожного стану моря. Дозволяє більш детально проаналізувати продуктивність моделі по кожному класу.

#### 2. Регресія:

– середня абсолютна похибка (MAE): оцінка середнього абсолютного відхилення між прогнозованими значеннями моделі та фактичними значеннями. Це дає можливість виміряти точність моделі при прогнозуванні безперервних значень параметрів руху судна;

– середня квадратична похибка (MSE): вимірює стандартне відхилення між прогнозованими значеннями та фактичними значеннями. MSE дозволяє більш чутливо реагувати на великі помилки, і це може бути корисно, коли важливо мінімізувати великі відхилення в прогнозах.

Важливо враховувати специфіку завдання і специфіку даних про рух судна при виборі метрик для оцінки моделі. Наприклад, якщо завдання оцінки стану моря вимагає високої точності при класифікації різних станів, то метрики, пов'язані з точністю і матрицею помилок, можуть бути найважливішими. З іншого боку, якщо завдання полягає в прогнозуванні безперервних значень параметрів руху судна, кращими можуть бути такі регресійні метрики, як MAE і MSE.

### Висновки

Таким чином результати побудови запропонованої глибокої нейромережевої моделі оцінки стану моря мають такі переваги:

1. Висока точність. Модель здатна досягти

високої точності в оцінці стану моря на основі даних про рух судна. Це дозволяє приймати більш достовірні рішення і прогнозувати можливі зміни морських умов.

2. Врахування залежностей і динаміки. Архітектура мережі на основі щільно пов'язаних згорткових нейронних мереж (DenseNet) дозволяє враховувати залежності і динаміку руху судна, що покращує

якість оцінки стану моря і робить модель більш адаптивною до умов, що змінюються.

3. Підвищення безпеки та ефективності. Використання такої моделі дає можливість підвищити безпеку і ефективність морських операцій. Більш точна оцінка стану моря допомагає в прийнятті обґрунтованих рішень, запобіганні можливих аварій і оптимізації використання ресурсів.

#### СПИСОК ЛІТЕРАТУРИ

1. Reiner, Carl, Detlefsen, Ole, and Moustafa Abdel-Maksoud. "On the Development of an Onboard Sea State Estimator Based on Numerical Vessel Motion Data." Paper presented at the The 32nd International Ocean and Polar Engineering Conference, Shanghai, China, June 2022. URL: <https://onepetro.org/ISOPEIOPEC/proceedings-abstract/ISOPE22/All-ISOPE22/493898> (дата звернення: 28.04.2023).
2. X. Cheng, G. Li, R. Skulstad, H. Zhang and S. Chen, "SpectralSeaNet: Spectrogram and Convolutional Network-based Sea State Estimation," IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society, Singapore, 2020, pp. 5069-5074, doi: 10.1109/IECON43393.2020.9254890.
3. Umair, M.; Hashmani, M.A.; Hussain Rizvi, S.S.; Taib, H.; Abdullah, M.N.; Memon, M.M. A Novel Deep Learning Model for Sea State Classification Using Visual-Range Sea Images. *Symmetry* 2022, 14, 1487. <https://doi.org/10.3390/sym14071487>.
4. Ulrik D. Nielsen, Malte Mittendorf, Yanlin Shao, Gaute Storhaug, Wave spectrum estimation conditioned on machine learning-based output using the wave buoy analogy, *Marine Structures*, Volume 91, 2023, 103470, ISSN 0951-8339, <https://doi.org/10.1016/j.marstruc.2023.103470>. (<https://www.sciencedirect.com/science/article/pii/S095183392300103X>).
5. Malte Mittendorf, Ulrik Dam Nielsen, Harry B. Bingham, Gaute Storhaug, Sea state identification using machine learning—A comparative study based on in-service data from a container vessel, *Marine Structures*, Volume 85, 2022, 103274, ISSN 0951-8339, <https://doi.org/10.1016/j.marstruc.2022.103274>.
6. Nielsen U. D. Sea state estimation based on measurements of wave-induced ship responses. – Technical University of Denmark, 2018.
7. Nielsen U. D. A concise account of techniques available for shipboard sea state estimation // *Ocean Engineering*. – 2017. – Т. 129. – С. 352-362.
8. Takekuma K. On the Evaluation of Sea Spectra based on the Measured Ship Motions // *Західна суднобудівна асоціація*. – 1973. – №. 45. – С. 51-57.
9. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
10. X. Cheng, G. Li, A. L. Ellefsen, S. Chen, H. P. Hildre and H. Zhang, "A Novel Densely Connected Convolutional Neural Network for Sea-State Estimation Using Ship Motion Data," in *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 9, pp. 5984-5993, Sept. 2020, doi: 10.1109/TIM.2020.2967115.
11. Lai, Zhichen, et al. "Multiscale wavelet-driven graph convolutional network for blade icing detection of wind turbines." *IEEE Sensors Journal* 22.22 (2022): 21974-21985.

Received (Надійшла) 10.06.2023

Accepted for publication (Прийнята до друку) 23.08.2023

#### Development of a model of a deep neural network for assessing the state of the sea on the basis of the ship's motion

Iryna Hannoshyna

**Abstract.** The aim of the work is to develop a deep neural network model for estimating the state of the sea based on the movement of a ship using densely connected convolutional neural networks to improve the safety and efficiency, accuracy, dependence, and dynamics of the sea state estimation for solving classification problems and regression problems. As a result of building a model of a deep neural network for assessing the state of the sea based on the movement of a vessel, the following results were obtained: initially, a network architecture was developed based on densely connected convolutional neural networks (DenseNet) with a unique combination of modifications and layers. Such an architecture effectively considers the dependencies and dynamics of the vessel's movement, which leads to a more accurate assessment of the state of the sea; secondly, the network was trained on prepared vessel motion data using optimizers and loss functions selected in accordance with the task of assessing the state of the sea. The training process included tuning hyperparameters, optimizing weights, and evaluating model performance against test data; thirdly, the model was evaluated from the test data using appropriate metrics depending on the specific task of assessing the state of the sea. For example, the accuracy and error matrix were used for the classification task, and the mean absolute error (MAE) and root mean square error (MSE) were used for the regression task. The results of building a deep neural network model for estimating the state of the sea based on the movement of a vessel confirm its effectiveness and significance for research purposes. The application of such a model is important in the context of assessing the state of the sea. The high accuracy of the estimate helps to make more reliable decisions and predict possible changes in accordance with the sea conditions that are currently occurring in the movement of the vessel. Considering the dependencies and dynamics of the vessel's movement allows modeling and adapting to changing conditions, which increases its manufacturability and efficiency. The use of such a model helps to improve the safety and efficiency of offshore operations, optimize the use of resources, and prevent possible accidents. Thus, a deep neural network model developed to estimate the state of the sea based on the movement of a vessel is an effective tool for the safety and efficiency of navigation. Its use contributes to more accurate forecasts and informed decision-making, which is important for maritime operations and ensuring the safety of navigation in general.

**Keywords:** deep neural network, network model, sea state estimation, vessel motion, tightly coupled convolutional neural network.