

КОНЦЕПТУАЛЬНА ДИНАМІЧНА МОДЕЛЬ ФУНКЦІОНАЛЬНОГО СТАНУ ОПЕРАТОРА З УРАХУВАННЯМ ВЗАЄМОДІЇ ФІЗІОЛОГІЧНИХ, КОГНІТИВНИХ ТА ОПЕРАЦІЙНИХ ФАКТОРІВ ІЗ ML-КОРЕКЦІЄЮ

Петровський А. В., *к.т.н., доцент кафедри навігації та управління судном Херсонської державної морської академії, м. Херсон, Україна, e-mail: andreyanobody@gmail.com, ORCID: 0000-0002-3337-9577.*

У статті запропоновано гібридну динамічну модель функціонального стану оператора в морських транспортних системах, яка враховує взаємодію фізіологічних, когнітивних та операційних факторів. Актуальність дослідження обумовлена значним впливом людського фактора на безпеку судноплавства, зокрема роллю втоми та когнітивного навантаження у виникненні аварійних ситуацій. Існуючі підходи до оцінки стану оператора, як правило, розглядають окремі аспекти цієї проблеми та не забезпечують інтегрованого опису процесів. У роботі розроблено динамічну модель, що описує зміну фізіологічної втоми, когнітивного навантаження та характеристик операційного середовища у часі з урахуванням їх нелінійної взаємодії. Особливістю запропонованого підходу є використання методів машинного навчання для корекції залишкової похибки базової моделі, що дозволяє підвищити точність прогнозування без втрати інтерпретованості результатів. У якості методу машинного навчання застосовано градієнтний бустинг. Надано структурно-логічні схеми реалізації моделі та представлено детальний алгоритм, які загалом надають повне уявлення всієї концепції моделі. Запропонована модель може бути використана як основа для побудови систем підтримки прийняття рішень у морських транспортних системах та підвищення рівня безпеки судноплавства.

Ключові слова: втома оператора; індекс PFI; безпека судноплавства; ML; градієнтний бустинг.

DOI: 10.33815/2313-4763.2026.1.32.100-113

Вступ. Забезпечення безпеки судноплавства є однією з ключових задач сучасної морської індустрії, у якій людський фактор відіграє визначальну роль. Незважаючи на розвиток автоматизованих систем управління, оператор залишається центральною ланкою прийняття рішень у складних навігаційних умовах. Численні дослідження показують, що значна частина морських інцидентів пов'язана з помилками людини, серед яких особливе місце займає втома. Втома оператора впливає на увагу, швидкість реакції та якість прийняття рішень, що безпосередньо підвищує ризик аварійних ситуацій.

Складність аналізу цього явища полягає в його багатфакторній природі, оскільки втома формується під впливом фізіологічних, когнітивних та зовнішніх факторів. До фізіологічних факторів належать порушення сну, тривалість роботи та циркадні ритми, тоді як когнітивне навантаження визначається складністю задач і рівнем інформаційного перевантаження. Операційні умови, зокрема інтенсивність суднопотоку та навігаційна обстановка, також суттєво впливають на стан оператора. Взаємодія цих факторів має нелінійний характер і може призводити до різкого погіршення функціонального стану навіть при незначних змінах умов.

Постановка проблеми. Існуючі підходи до оцінки втоми та ризику, як правило, розглядають окремі аспекти цієї проблеми. Біоматематичні моделі ефективно описують фізіологічні процеси, але не враховують когнітивне навантаження. У свою чергу, когнітивні моделі базуються на суб'єктивних оцінках і не відображають фізіологічну динаміку. Методи машинного навчання дозволяють досягати високої точності прогнозування, проте часто використовуються як "чорний ящик" без фізичної інтерпретації. Це обмежує їх застосування у критичних системах, де важлива пояснюваність результатів.

Таким чином, актуальною є задача розробки інтегрованого підходу, який поєднує фізіологічні, когнітивні та операційні фактори в єдиній моделі. Особливого значення набуває врахування динамічного характеру процесів та нелінійної взаємодії між складовими. Крім того, необхідним є використання методів машинного навчання у спосіб, що зберігає інтерпретованість моделі та підвищує її точність.

Аналіз досліджень і публікацій. Сучасні дослідження демонструють, що людський фактор є причиною більшості інцидентів, при цьому втома часто виступає латентною причиною, яка не відображається у звітах про аварії [1, 2]. Аналіз аварійних даних із використанням статистичних та машинних методів показує, що ігнорування втоми призводить до недооцінки ризиків і спотворення моделей безпеки [1, 3].

Втома формується під впливом комплексу факторів, включаючи тривалість роботи, порушення сну, організаційні умови та індивідуальні характеристики оператора [4, 5]. Дослідження психофізіологічного стану моряків показують, що ці фактори взаємодіють між собою та створюють нелінійну систему, у якій навіть невеликі зміни умов можуть призводити до значного погіршення стану [6, 7]. У зв'язку з цим застосовуються різні методи оцінки втоми, включаючи фізіологічні, поведінкові та суб'єктивні підходи. Фізіологічні методи базуються на аналізі біосигналів, поведінкові – на характеристиках виконання задач, тоді як суб'єктивні методи використовують опитувальники [4, 6].

Окремий напрям досліджень пов'язаний із оцінкою когнітивного навантаження, яке є критичним фактором ефективності оператора. Широко використовується індекс NASA-TLX, який дозволяє оцінити багатовимірну структуру навантаження [8, 9]. Дослідження показують, що підвищене когнітивне навантаження призводить до зниження уваги, збільшення часу реакції та зростання ймовірності помилок [10, 11]. При цьому встановлено, що рівень навантаження залежить від складності задачі, досвіду оператора та умов середовища [11, 12]. Попри широке застосування, ці підходи мають обмеження, зокрема суб'єктивність оцінки та відсутність динамічного опису процесів.

Важливу роль у сучасних дослідженнях відіграють операційні дані, зокрема AIS, які дозволяють оцінювати навігаційне середовище. AIS-дані використовуються для аналізу щільності трафіку, прогнозування траєкторій та виявлення аномалій [13, 14]. Застосування методів машинного навчання до AIS-даних дозволяє автоматично визначати складні сценарії руху суден та оцінювати рівень ризику [15, 16]. Це створює основу для інтеграції зовнішніх умов у моделі людського стану.

Методи машинного навчання набули значного поширення у задачах аналізу ризику та втоми. Вони дозволяють виявляти складні нелінійні залежності та взаємодії між факторами [1], [17]. Зокрема, застосування ансамблевих методів та неймереж дозволяє підвищити точність прогнозування стану оператора та ймовірності інцидентів [9, 18]. Додатково, сучасні дослідження пропонують мультимодальні підходи, які поєднують фізіологічні сигнали, поведінкові характеристики та контекстні дані [19], [20].

Разом із тим, ML-підходи мають суттєві обмеження. Основною проблемою є їх низька інтерпретованість, що ускладнює використання у критичних системах безпеки [17]. Крім того, такі моделі є чутливими до якості даних і можуть демонструвати нестабільність при зміні умов [3]. Це обмежує їх практичне застосування без додаткових обмежень та контролю. У відповідь на ці обмеження сучасні дослідження переходять до гібридних підходів, які поєднують фізично обґрунтовані моделі та машинне навчання. Такі підходи дозволяють зберегти інтерпретованість базових моделей і водночас врахувати складні нелінійні ефекти [9, 17]. Вони передбачають використання фізичних або експертних моделей як базового рівня з подальшою корекцією за допомогою ML (machine learning).

Таким чином, аналіз літератури показує, що існуючі підходи до моделювання втоми та ризику в морських системах розвиваються у трьох основних напрямках: фізіологічні моделі, когнітивні моделі та ML-підходи. Однак їх інтеграція залишається обмеженою, що обґрунтовує необхідність розробки гібридних моделей, які поєднують фізіологічні, когнітивні та операційні фактори з використанням машинного навчання.

Основний науковий розрив полягає у відсутності інтегрованої моделі, яка одночасно:

- враховує фізіологічний стан оператора;
- описує когнітивне навантаження;
- інтегрує операційні умови (зокрема AIS-дані);

- враховує динаміку процесів;
- моделює нелінійні взаємодії факторів;
- і при цьому зберігає інтерпретованість.

Метою даної роботи є розробка гібридної моделі оцінки стану оператора, яка інтегрує фізіологічні, когнітивні та операційні фактори з використанням машинного навчання для корекції залишкової похибки. Запропонований підхід дозволяє врахувати складну структуру взаємодій між факторами та підвищити достовірність прогнозування ризику в умовах реальної експлуатації.

Об'єктом дослідження є функціональний стан оператора в морських транспортних системах, який формується під впливом фізіологічної втоми, когнітивного навантаження та операційних умов навігаційного середовища.

Задачі дослідження: розробити динамічну модель функціонального стану оператора, що включає фізіологічну втому, когнітивне навантаження та операційні фактори; формалізувати взаємодію складових моделі з урахуванням нелінійних ефектів і контекстних змінних (ніч, трафік, перевтома); реалізувати ML-корекцію моделі на основі градієнтного бустингу для зменшення похибки прогнозу.

Методи дослідження: математичне моделювання динамічних процесів; нелінійний аналіз взаємодії факторів; методи машинного навчання (градієнтний бустинг для residual-корекції).

Основна частина. У роботі [21] побудовано базову модель визначення рівня втоми штурмана Predictive Fatigue Index (PFI): $PFI = f(F, C, O)$, де кожна складова вже має свою формалізацію:

де F – через сон і час активності;

C – через задачі, повідомлення, складність;

O – через погоду, трафік, ніч.

Між складовими немає динамічного зв'язку.

З метою підвищення точності прогнозування рівня втоми судноводія запропоновано розширення базової моделі PFI шляхом введення динамічної еволюції складових та врахування їх взаємного впливу. На відміну від статичних представлень, складові фізіологічного стану, когнітивного навантаження та операційного ризику є сенс розглянути як часові процеси, що змінюються у дискретному часі.

Для динамічного розширення моделі кожену складову моделі можна описати рівнянням стану:

- фізіологічна втома:

$$F(t + \Delta t) = F(t) + \alpha_1 D_{sleep}(t) + \alpha_2 T_{work}(t) + \alpha_3 R(t) \quad (1)$$

де D_{sleep} – дефіцит сну;

T_{work} – тривалість безперервної активності;

$R(t)$ – відновлення;

α_1 – вплив дефіциту сну;

α_2 – накопичення втоми;

α_3 – швидкість відновлення.

$$\alpha_1 + \alpha_2 + \alpha_3 = 1$$

- когнітивне навантаження:

$$C(t + \Delta t) = C(t) + \beta_1 W(t) + \beta_2 M(t) + \beta_3 A(t) \quad (2)$$

де $W(t)$ – кількість задач;

$M(t)$ – інтенсивність повідомлень;

$A(t)$ – адаптація оператора;

β_1 – вплив задач;

β_2 – вплив повідомлень;

β_3 – ефект адаптації.

$$\beta_1 + \beta_2 + \beta_3 = 1$$

– операційний ризик:

$$O(t + \Delta t) = \gamma_1 Weather(t) + \gamma_2 Traffic(t) + \gamma_3 Night(t) \quad (3)$$

де $Weather(t)$ – складність погодних умов;

$Traffic(t)$ – інтенсивність трафіку (за кількістю суден з AIS-помітками);

$Night(t)$ – зміна частин доби, $Night(t) \in [0; 1]$;

γ_1 – вплив погодних умов на втомленість штурмана;

γ_2 – вплив насиченості трафіку;

γ_3 – потенційний вплив частини доби на втомленість.

$$\gamma_1 + \gamma_2 + \gamma_3 = 1$$

Інтегральний показник визначається як:

$$PFI_{base}(t) = w_F(t) F(t) + w_C C^*(t) + w_O O(t) \quad (4)$$

де w_F , w_C , w_O – вагові коефіцієнти, $w_F + w_C + w_O = 1$.

На відміну від незалежного розгляду складових, у запропонованій моделі вводиться їх взаємний вплив. Наприклад, фізіологічна втома підсилює когнітивне навантаження:

$$C^*(t) = C(t)(1 + \lambda_F F(t)) \quad (5)$$

де λ_F – коефіцієнт впливу втоми на когнітивні процеси, а, наприклад, когнітивне навантаження прискорює накопичення втоми:

$$F(t + \Delta t) = F(t) + \lambda_C C^*(t) \quad (6)$$

де λ_C – коефіцієнт впливу когнітивних процесів на втому.

При цьому операційні фактори можуть моделювати обидві складові (вплив операційних факторів на фізіологічний стан λ_{OF}):

$$C^*(t) = C(t)(1 + \lambda_{OF} O(t)), \quad F(t) = F(t)(1 + \lambda_{OF} O(t)) \quad (7)$$

Таким чином, система набуває нелінійного характеру, що дозволяє врахувати ефект «каскадного» зростання навантаження:

втома → *зниження уваги* → *зростання когнітивного навантаження* → *ще більша втома* → *зниження уваги* → *зростання когнітивного навантаження* → *ще більша втома*.

Тоді з урахуванням динаміки та взаємодії компонентів прогноз рівня втоми визначається як:

$$PFI_{base}(t + \Delta t) = f(F(t + \Delta t), C^*(t + \Delta t), O(t + \Delta t)) + \varepsilon_{ML} \quad (8)$$

де ε_{ML} – корекція на основі машинного навчання.

У реальних умовах така формальна модель свідчить, що однакова кількість задач при різному рівні втоми дає різний ризик, також нічні умови не лише додають ризик, а й підсилюють дію інших факторів. Така модель здатна виявляти приховані критичні стани, коли оператор ще формально у нормальному стані, але система вже прогнозує різке погіршення.

Для практичного застосування запропонованої динамічної моделі необхідно визначити параметри, діапазони змін змінних та методи їх ідентифікації. У даній роботі використовується комбінований підхід, що поєднує експертну ініціалізацію, нормалізацію вхідних даних та подальше уточнення параметрів за допомогою даних (data-driven).

Запропонована модель складається з двох функціонально відокремлених рівнів. Перший рівень – аналітична (базова) модель, що формує первинну оцінку індексу функціонального стану на основі фізіологічних, когнітивних та операційних змінних. Другий рівень – модуль машинного навчання, який не замінює базову модель, а виконує корекцію її залишкової похибки, враховуючи нелінійні залежності та індивідуальні особливості, не охоплені аналітичним описом.

Другий рівень моделі – ML-підхід.

Математична модель ML-корекції PFI:

$$PFI(t) = PFI_{base}(t) + \varepsilon_{ML}(t) \quad (9)$$

Формуємо вхідний вектор:

$$x(t) = [F(t), C(t), O(t), D_{sleep}(t), T_{work}(t), R(t), W(t), M(t), A(t), Weather(t), Traffic(t), Night(t)]$$

Корекція:

$$\varepsilon_{ML}(t) = f_{\theta}(x(t), h(t)) \quad (10)$$

де f_{θ} – ML-модель;

$h(t)$ – історичний стан (пам'ять).

При виборі градієнтного бустингу:

$$\varepsilon_{ML}(t) = \sum_{k=1}^K \alpha_k h_k(x(t))$$

де: h_k – слабкі моделі (дерева рішень);

K – кількість ітерацій.

Перевагою використання градієнтного бустингу є визначення нелінійності параметрів. Таким чином, модуль машинного навчання виконує виключно функцію корекції залишкової похибки базової аналітичної моделі. Це забезпечує збереження фізичної інтерпретованості основних компонентів, тоді як ML-модуль компенсує невраховані нелінійні ефекти, міжфакторні взаємодії та індивідуальні особливості оператора.

Навчання моделі через цільову функцію:

$$y(t) = PFI_{real}(t) - PFI_{base}(t) \quad (11)$$

Тобто модель вчиться саме помилці.

Мінімізується функція помилки (функція втрат):

$$\min_{\{\alpha, \beta, \gamma, \lambda\}} \sum_t (y(t) - f_0(x(t)))^2 \quad (12)$$

$$\min_{\{\alpha, \beta, \gamma, \lambda\}} \sum_t (f_0(x(t)) - (PFI_{real} - PFI_{base}))^2$$

Адаптація моделі (через Exponential Moving Average, EMA):

$$\varepsilon_{ML}(t) = \rho f_0(x(t)) + (1 - \rho) \varepsilon_{ML}(t - 1) \quad (13)$$

$\rho \in [0.1; 0.5]$

Обмеження моделі: $F(t), C(t), O(t), PFI(t) \in [0; 1]$

Значення насиченості (сатурація): $PFI(t) = \min(1, \max(0, PFI(t)))$. Наприклад, фізичні обмеження (сатурація для $F(t)$):

– сон < 0 – неможливо;

– часове навантаження $> \max$ – обрізка до максимального значення;

– логічні обмеження: при $F(t) \rightarrow 1$ ефективність знижується, а при $C(t) \rightarrow 1$ зростає ризик помилки $C(t) = \min(1, \max(0, C(t)))$.

Обмеження корекції: $\varepsilon_{ML}(t) \in [-\delta; +\delta]$, $\delta \in [0.1; 0.3]$.

ML-корекція ($\varepsilon_{ML}(t)$) фактично є індивідуальною поправкою штурмана, яка враховує: швидкість втомлення конкретного ООВ (вахтовий офіцер навігаційного містка), реакцію на нічні зміни та на поведінку в умовах перевантаження.

Остаточна модель:

$$PFI(t) = w_F F(t) + w_C C^*(t) + w_O O(t) + f_\theta(x(t)) \quad (14)$$

Запропонована система рівнянь (1)–(7) є нелінійною динамічною системою з обмеженими змінними стану $F(t), C(t), O(t) \in [0; 1]$.

Стійкість моделі забезпечується такими факторами:

– обмеженістю фазового простору: всі змінні нормалізовані, що виключає необмежене зростання; наявністю демпфуючих компонентів (у фізіологічній моделі – член відновлення $R(t)$, а у когнітивній – адаптація $A(t)$);

– балансом параметрів: система є стійкою за умов: $\alpha_3 \geq \alpha_2, \beta_3 \geq \beta_1 + \beta_2$ (в середньому), що відповідає фізичному сенсу відновлення;

– дисипативністю системи: при відсутності зовнішніх впливів ($W \rightarrow 0, Traffic \rightarrow 0$) система прямує до стаціонарного стану.

Таким чином, модель не демонструє нестійкості, а її поведінка обмежена фізично інтерпретованими межами.

Модель має динамічний характер та може бути формалізована у вигляді системи диференціальних рівнянь, однак у межах даної роботи розглядається на концептуальному рівні із акцентом на структурні та функціональні взаємозв'язки.

На рис. 1 представлено формальну схему взаємодії впливів та визначення поточного інтегрального показника PFI та його прогнозного значення.

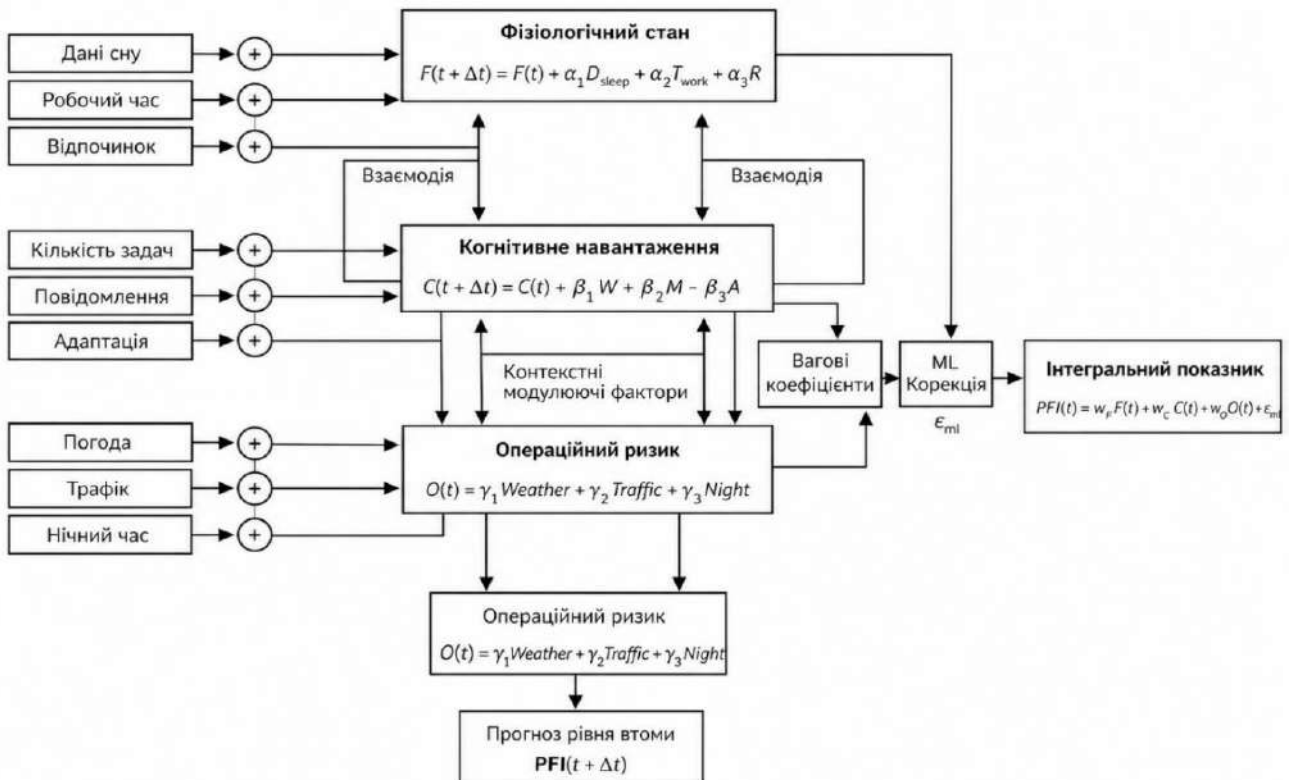


Рисунок 1 – Формальна схема взаємодії впливів та визначення інтегрального показника PFI

Структурно-логічна схема формальної моделі показує концептуальні моменти її реалізації (рис. 2).

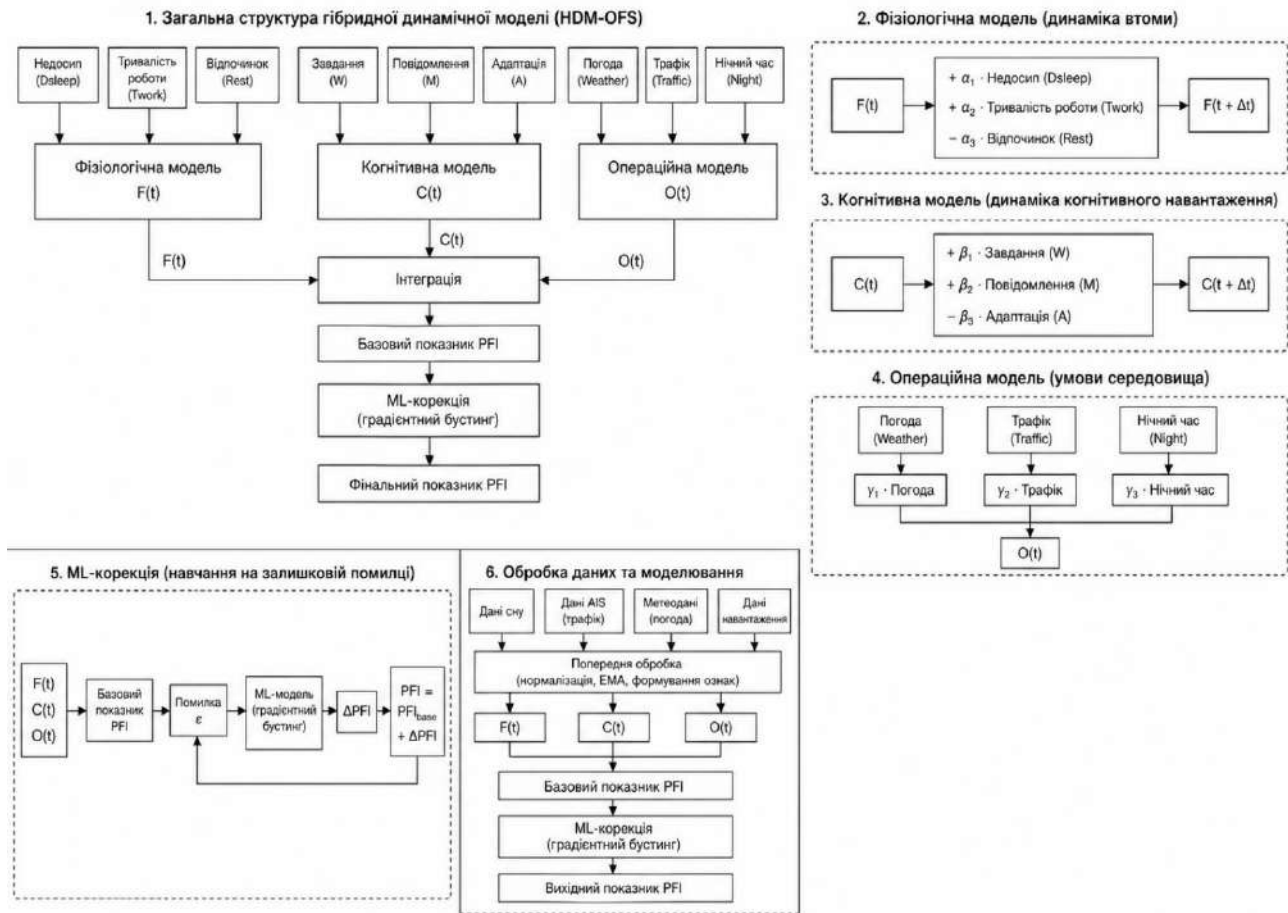


Рисунок 2 – Структурно-логічна схема визначення інтегрального PFI

Модель чутлива до нормалізації і тому її параметри потрібно калібрувати під тип судна, район плавання і екіпаж.

Усі складові призводяться до безрозмірного вигляду: $F(t), C(t), O(t), PFI(t) \in [0,1]$. Нормалізація надає можливість порівняння компонентів, стійкість моделі і коректну роботу вагових коефіцієнтів.

Приклад нормалізації. Фізіологія:

$$D_{sleep} = \max\left(0, \frac{T_{opt} - T_{sleep}}{T_{opt}}\right)$$

$$T_{work}^{norm} = \max\left(1, \frac{T_{work}}{T_{max}}\right)$$
(15)

Когнітивне навантаження:

$$W^{norm} = \frac{W}{W_{max}}, \quad M^{norm} = \frac{M}{M_{max}}$$
(16)

Розроблений алгоритм реалізації моделі (рис. 3) надає уявлення послідовності розрахунків, а по окремих компонентах – подальших досліджень.

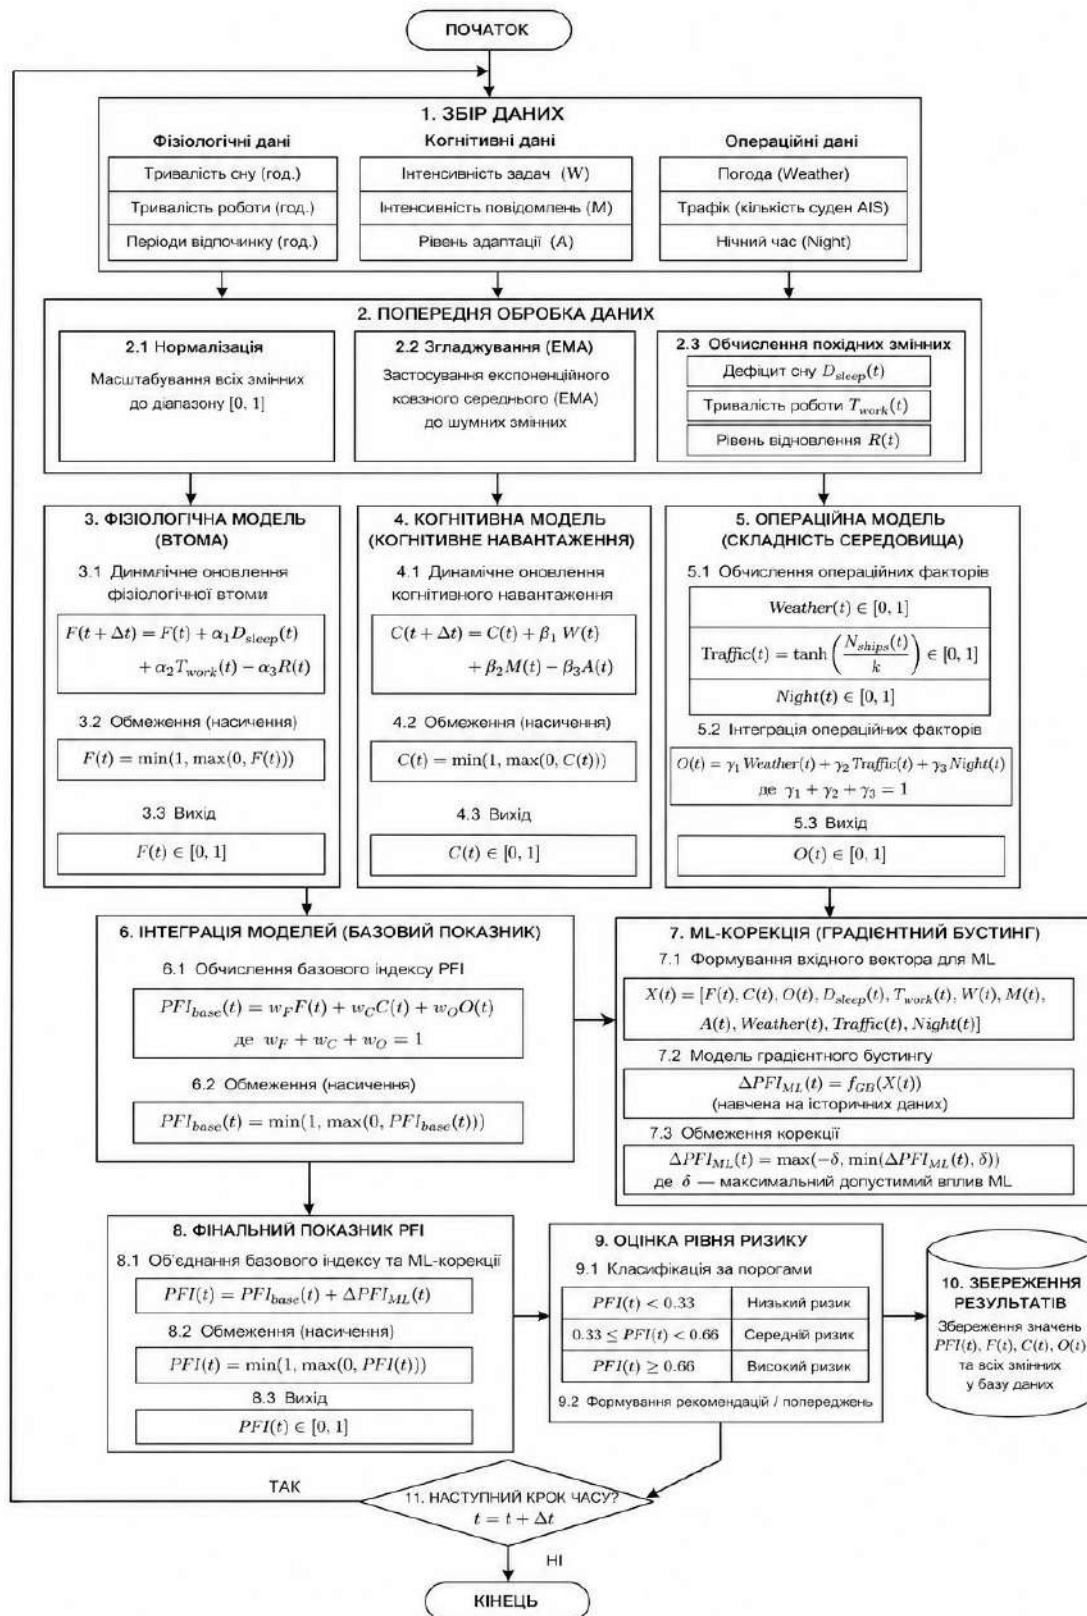


Рисунок 3 – Блок-схема визначення інтегрального PFI

Обговорення і результати досліджень.

Операційні фактори:

- $Weather \in [0; 1]$ (за шкалою Бофорта або індексом хмарності/ясності);
- $Traffic \in [0; 1]$ (щільність AIS);
- $Night \in \{0; 1\}$ або $[0,1]$ (як перехідна функція).

Припустимо, що коефіцієнти ($\alpha_i, \beta_i, \gamma_i$) визначають «швидкість накопичення» ефектів. Тоді у фізіологічній моделі рекомендовані діапазони для коефіцієнтів:

$\alpha_1 \in [0.05; 0.2]$ – вплив недосипу;

$\alpha_2 \in [0.01; 0.1]$ – накопичення втоми;

$\alpha_3 \in [0.05; 0.3]$ – швидкість відновлення.

Наприклад, якщо $\alpha_3 > \alpha_2$, то людина добре відновлюється, а навпаки – йде швидко накопичення втоми.

Для когнітивної моделі рекомендовані діапазони для коефіцієнтів:

$\beta_1 \in [0.05; 0.3]$ – вплив задач;

$\beta_2 \in [0.05; 0.25]$ – вплив повідомлень;

$\beta_3 \in [0.05; 0.2]$ – адаптація.

Для операційної моделі рекомендовані діапазони для коефіцієнтів: $\gamma_1, \gamma_2, \gamma_3 \in [0.2; 0.5]$.

Конкретні значення будь-яких коефіцієнтів можна розрахувати, наприклад, методом аналізу ієрархій (MAI), в якості вхідних даних обирати реальні показники втоми окремого штурмана. Будується матриця парних порівнянь (наприклад, *Traffic* важливіший за *Weather*, а *Night* -менш важливий):

	Weather	Traffic	Night
Weather	1	1/2	2
Traffic	2	1	3
Night	1/2	1/3	1

Після нормалізації отримані ваги складуть: $\gamma_1 = 0.30, \gamma_2 = 0.50, \gamma_3 = 0.20$. Головним залишається питання: як задавати значення для подальшого розрахування MAI ваг компонентів. По компоненті *Weather*, як приклад, бали по шкалі Бофорта / 12:

Умови	Бофорт	Значення Weather
штиль	0–1	0.0–0.1
слабкий вітер	2–3	0.2–0.3
помірний	4–5	0.4–0.6
сильний	6–7	0.7–0.8
шторм	8+	0.9–1.0

По компоненті *Traffic* (дані обирати по AIS з сайту marinetraffic.com):

$$Traffic = \frac{N_{ships}}{N_{max}} \quad (17)$$

N_{max} – максимальна кількість (за статистикою) судів у даній частині акваторії;

N_{ships} – поточна кількість судів.

По компоненті *Night* для врахування сутінок:

$$Night = (1 + e^{-k(t-t_{night})})^{-1} \quad (18)$$

Рівень втоми по факторах (дефіцит сну, за відновлення стану відповідає $R(t)$):

$$D_{sleep} = \max(0; 0.8 - Sleep) \quad (19)$$

$$D_{sleep} = \max(0; 8 - SleepHours)/8: \quad (20)$$

<i>Sleep</i>	D_{sleep}
8 год	0
6 год	0.25
4 год	0.5
0 год	1

Нормалізація D_{sleep} наведено у (19) $Sleep \in [0; 1]$, а фізичний сенс – (19) $SleepHours \in [0; 8]$.

Нормування по кількості відпрацьованих годин: $T_{work} = HoursWorked/12$.

MAI добре працює для операційної компоненти та впливу факторів навантаження, але гірше для фізіології (тут краще калібрувати по даних).

Таким чином MAI дає стартові ваги, а потім ML (бустинг) – корекція:

$$\alpha_i^{final} = \alpha_i^{MAI} + \Delta\alpha_i^{ML}$$

Додатково можна ввести контроль за стабільністю значень: $\lambda_F + \lambda_C < 1$ (саме ці компоненти можуть приймати найбільші значення).

Типовими значення ваг можуть бути: $w_F = 0.4$; $w_C = 0.35$; $w_O = 0.25$, але вночі збільшується w_F , а у складній навігації – w_C .

Методами оцінки параметрів можуть бути: IMO рекомендації (International Maritime Organization), правила несення вахти, досвід штурманів.

Подалі, порівнюючи різні моделі, можна скласти таблицю порівняння по можливостях використання у моделях параметрів:

Таблиця 1 – Порівняльна таблиця підходів до моделювання рівня втоми

Підхід	Фізіологія	Когнітивність	AIS / середовище	Динаміка	ML	Інтерпретованість
Фізіологічні моделі	+	–	–	+	–	+
Когнітивні моделі	–	+	–	–	–	+
AIS / операційні моделі	–	–	+	+	+	–
ML (data-driven)	–	+	+	+	+	–
Гібридні моделі	+	+	+	+	+	+

Висновки. У роботі запропоновано гібридний підхід до моделювання стану оператора та оцінки ризику, який поєднує фізично інтерпретовану структуру моделі з методами машинного навчання. Запропоновано єдину модель, що об'єднує три ключові компоненти: фізіологічний стан (втома), когнітивне навантаження, операційне середовище (на основі AIS-даних). На відміну від існуючих підходів, ці компоненти розглядаються не ізольовано, а як взаємопов'язана система. Також на відміну від статичних моделей, запропонований підхід враховує часову еволюцію стану оператора, що дозволяє описати процес накопичення втоми та зміну навантаження у часі. У моделі явно враховано взаємодію між компонентами, зокрема: вплив фізіологічної втоми на когнітивну ефективність, посилення навантаження в умовах високого трафіку, порогові ефекти перевтоми, що дозволяє адекватно описати складні сценарії, які не відображаються у лінійних моделях. Було застосовано концепцію residual learning, у якій машинне навчання не замінює базову модель, а використовується для корекції її похибки, що забезпечує збереження фізичної інтерпретації, підвищення точності і стабільність моделі при обмеженому обсязі даних. Введені контекстні змінні (наприклад, нічний режим, інтенсивність трафіку, перевтома), які формуються на основі реальних даних, враховуються у ML-компоненті. Для моделювання залишкової похибки базової моделі використано метод градієнтного бустингу, у якому функція корекції представляється у вигляді суми слабких моделей (дерев рішень). На кожній ітерації здійснюється апроксимація

залишкової похибки попереднього кроку, що дозволяє послідовно зменшувати загальну помилку моделі. Такий підхід забезпечує врахування нелінійних залежностей, взаємодії факторів та контекстних умов при збереженні інтерпретованості моделі. Модель зберігає можливість інтерпретації результатів, оскільки базова частина має фізичний зміст, а МЛ використовується лише для корекції, також внесок кожного фактору може бути проаналізований окремо. Такий підхід дозволяє врахувати нелінійні взаємодії факторів, забезпечити інтерпретованість та підвищити точність прогнозування стану оператора. Надані концептуальні схеми реалізації моделі та алгоритм дій, запропонованою блок-схемою.

Перспективи подальших досліджень. Перспективи подальших досліджень полягають у проведенні експериментальної валідації запропонованої моделі на основі реальних даних суднової експлуатації, зокрема фізіологічних показників операторів, даних AIS та параметрів навігаційного середовища. Важливим напрямом також є адаптація моделі до індивідуальних особливостей операторів шляхом персоналізації параметрів та використання методів онлайн-навчання.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Fan S., Yang Z. Accident data-driven human fatigue analysis in maritime transport using machine learning, *Reliability Engineering & System Safety*, Volume 241, 2024, 109675, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2023.109675>.
2. Crestelo Moreno F., Soto-López V., García Maza J. A., Sernaglia M. Fatigue as a latent risk factor in maritime safety systems: A systematic review and implications for reliability analysis, *Reliability Engineering & System Safety*, Volume 267, Part B, 2026, 111930, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2025.111930>.
3. Matsangas P., & Shattuck N. L. Discriminating Between Fatigue and Sleepiness in the Naval Operational Environment. *Behavioral Sleep Medicine*, 16(5), 427–436. 2018. <https://doi.org/10.1080/15402002.2016.1228645>.
4. Kerkamm F., Dengler D., et al. Measurement Methods of Fatigue, Sleepiness and Sleep Behaviour Aboard Ships: A Systematic Review. *Int J Environ Res Public Health*. 2021, Vol.19(1):120. <https://doi.org/10.3390/ijerph19010120>.
5. Ma M., Liao R. Factors affecting seafarers' fatigue: a scoping review. *Front Public Health*. 2025 Vol.13:1647685. <https://doi.org/10.3389/fpubh.2025.1647685>.
6. Yisi Liu, Zirui Lan, Jian Cui, Gopala Krishnan, Olga Sourina, Dimitrios Konovessis, Hock Eng Ang, Wolfgang Mueller-Wittig, Psychophysiological evaluation of seafarers to improve training in maritime virtual simulator, *Advanced Engineering Informatics*, Vol.44, 2020, 101048, ISSN 1474-0346, <https://doi.org/10.1016/j.aei.2020.101048>. Mao S. et al. (2016).
7. Mao S., Tu E, Zhang G., et al. An Automatic Identification System (AIS) Database for Maritime Trajectory Prediction and Data Mining, *Computer Science > Databases*, 2016, 1607.03306, <https://doi.org/10.48550/arXiv.1607.03306>.
8. Moreno F., Soto-López V., et al. Fatigue as a key human factor in complex sociotechnical systems: Vessel Traffic Services. *Front. Public Health*, 2024, Vol.11:1160971. <https://doi.org/10.3389/fpubh.2023.1160971>.
9. Cao-Feijóo G., Pérez-Canosa J. M., et al. Deep Learning Methods to Mitigate Human-Factor-Related Accidents in Maritime Transport. *J. Mar. Sci. Eng.* 2024, 12, 1819. <https://doi.org/10.3390/jmse12101819>.
10. Miklody D., Uitterhoeve W. M., van Heel D., Klinkenberg K., Blankertz B. Maritime Cognitive Workload Assessment. *Symbiotic Interaction. Symbiotic 2016. Lecture Notes in Computer Science*, vol 9961. Springer, 2027. Cham. https://doi.org/10.1007/978-3-319-57753-1_9.

11. Main L. C., Wolkow A., Chambers T. P. Quantifying the Physiological Stress Response to Simulated Maritime Pilotage Tasks: The Influence of Task Complexity and Pilot Experience. *J Occup Environ Med.* 2017. Nov; 59(11):1078-1083. <https://doi.org/10.1097/JOM.0000000000001161>.
12. NASA/TM—2018–219934. San Francisco Bar Pilot Fatigue Study, NASA Langley Research Center, Hampton, VA 23681-2199, 2018, p. 137. <https://ntrs.nasa.gov/api/citations/20190002704/downloads/20190002704.pdf>.
13. Tu E, Zhang G., et al. Exploiting AIS Data for Intelligent Maritime Navigation: A Comprehensive Survey, *Computer Science. Other Computer Science*, Vol.1606.00981, 2016. <https://doi.org/10.48550/arXiv.1606.00981>.
14. Singh S. K., Heymann F. Machine Learning-Assisted Anomaly Detection in Maritime Navigation Using AIS Data. *Electrical Engineering and Systems Science. Signal Processing*, Vol. 2002. 05013, 2020. <https://doi.org/10.48550/arXiv.2002.05013>.
15. Nguyen D. et al. A Multi-task Deep Learning Architecture for Maritime Surveillance using AIS Data Streams. *Computer Science. Machine Learning*, Vol. 1806.03972, 2018. <https://doi.org/10.1109/DSAA.2018.00044>.
16. Xue J., Yang P., et al. Machine Learning in Maritime Safety for Autonomous Shipping: A Bibliometric Review and Future Trends. *J. Mar. Sci. Eng.* 2025, 13, 746. <https://doi.org/10.3390/jmse13040746>.
17. Jiang Y, Tang Z, Liu H, et al. Work-Life Conditions as the Primary Determinant of Seafarer Mental Health: An Explainable Machine Learning Analysis. *INQUIRY: The Journal of Health Care Organization, Provision, and Financing.* 2026;63. <https://doi.org/10.1177/00469580261438708>.
18. Ma X., Liu Q., et al. Machine learning-based multimodal fusion recognition of passenger ship seafarers' workload: A case study of a real navigation experiment, *Ocean Engineering*, Vol. 300, 2024, 117346, ISSN 0029-8018, <https://doi.org/10.1016/j.oceaneng.2024.117346>.
19. Zhang X. et al. Towards operational safety in maritime transportation: a neurophysiological workload measurement using deep learning, *Ocean Engineering*, 2026.
20. Volume 351, Part 2, 2026, 124399, ISSN 0029-8018, <https://doi.org/10.1016/j.oceaneng.2026.124399>.
21. Петровський А. В. Динамічна модель розрахунку рівня втоми штурмана – Predictive fatigue index, *Науковий вісник Херсонської державної морської академії*, Т(31), 2025, С. 199–208 <https://doi.org/10.33815/2313-4763.2025.2.31.199-208>.

REFERENCES

1. Fan, S., Yang, Z. (2024). Accident data-driven human fatigue analysis in maritime transport using machine learning, *Reliability Engineering & System Safety*, Volume 241, 109675, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2023.109675>.
2. F. Crestelo Moreno, V. Soto-López, J. A. García Maza, M. (2026). Sernaglia, Fatigue as a latent risk factor in maritime safety systems: A systematic review and implications for reliability analysis, *Reliability Engineering & System Safety*, Volume 267, Part B, 111930, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2025.111930>.
3. Matsangas, P., & Shattuck, N. L. (2018). Discriminating Between Fatigue and Sleepiness in the Naval Operational Environment. *Behavioral Sleep Medicine*, 16(5), 427–436. <https://doi.org/10.1080/15402002.2016.1228645>.

4. Kerkamm, F., Dengler, D. et al. (2021). Measurement Methods of Fatigue, Sleepiness and Sleep Behaviour Aboard Ships: A Systematic Review. *Int J Environ Res Public Health*. Vol.19(1):120. <https://doi.org/10.3390/ijerph19010120>.
5. Ma, M., Liao, R. (2025). Factors affecting seafarers' fatigue: a scoping review. *Front Public Health*. Vol.13:1647685. <https://doi.org/10.3389/fpubh.2025.1647685>.
6. Yisi Liu, Zirui Lan, Jian Cui, Gopala Krishnan, Olga Sourina, Dimitrios Konovessis, Hock Eng Ang, Wolfgang Mueller-Wittig (2020). Psychophysiological evaluation of seafarers to improve training in maritime virtual simulator, *Advanced Engineering Informatics*, Vol.44, 101048, ISSN 1474-0346, <https://doi.org/10.1016/j.aei.2020.101048>. Mao S. et al. (2016).
7. Mao, S., Tu, E, Zhang, G. et al. (2016). An Automatic Identification System (AIS) Database for Maritime Trajectory Prediction and Data Mining, *Computer Science > Databases*, 1607.03306, <https://doi.org/10.48550/arXiv.1607.03306>.
8. Moreno, F., Soto-López, V. et al. (2024). Fatigue as a key human factor in complex sociotechnical systems: Vessel Traffic Services. *Front. Public Health*, Vol.11:1160971. <https://doi.org/10.3389/fpubh.2023.1160971>.
9. Cao-Feijóo, G., Pérez-Canosa, J. M. et al. (2024). Deep Learning Methods to Mitigate Human-Factor-Related Accidents in Maritime Transport. *J. Mar. Sci. Eng.*, 12, 1819. <https://doi.org/10.3390/jmse12101819>.
10. Miklody, D., Uitterhoeve, W. M., van Heel, D., Klinkenberg, K., Blankertz, B. (2017). Maritime Cognitive Workload Assessment. *Symbiotic Interaction*. *Symbiotic 2016. Lecture Notes in Computer Science*, vol 9961. Springer, Cham. https://doi.org/10.1007/978-3-319-57753-1_9.
11. Main, L. C., Wolkow, A., Chambers, T. P. (2017). Quantifying the Physiological Stress Response to Simulated Maritime Pilotage Tasks: The Influence of Task Complexity and Pilot Experience. *J Occup Environ Med*. Nov;59(11):1078-1083. <https://doi.org/10.1097/JOM.0000000000001161>.
12. NASA/TM—2018–219934. (2018). San Francisco Bar Pilot Fatigue Study, NASA Langley Research Center, Hampton, VA 23681-2199, p. 137 <https://ntrs.nasa.gov/api/citations/20190002704/downloads/20190002704.pdf>.
13. Tu, E, Zhang, G. et al. (2016). Exploiting AIS Data for Intelligent Maritime Navigation: A Comprehensive Survey, *Computer Science. Other Computer Science*, Vol. 1606.00981, <https://doi.org/10.48550/arXiv.1606.00981>.
14. Singh, S. K., Heymann, F. (2020). Machine Learning-Assisted Anomaly Detection in Maritime Navigation Using AIS Data. *Electrical Engineering and Systems Science. Signal Processing*, Vol. 2002.05013, <https://doi.org/10.48550/arXiv.2002.05013>.
15. Nguyen, D. et al. (2018). A Multi-task Deep Learning Architecture for Maritime Surveillance using AIS Data Streams. *Computer Science. Machine Learning*, Vol. 1806.03972, <https://doi.org/10.1109/DSAA.2018.00044>.
16. Xue, J., Yang, P. et al. (2025). Machine Learning in Maritime Safety for Autonomous Shipping: A Bibliometric Review and Future Trends. *J. Mar. Sci. Eng.*, 13, 746. <https://doi.org/10.3390/jmse13040746>.
17. Jiang, Y., Tang, Z., Liu, H. et al. (2026). Work-Life Conditions as the Primary Determinant of Seafarer Mental Health: An Explainable Machine Learning Analysis. *INQUIRY: The Journal of Health Care Organization, Provision, and Financing*. 2026;63. <https://doi.org/10.1177/00469580261438708>.
18. Ma, X., Liu, Q. et al. (2024). Machine learning-based multimodal fusion recognition of passenger ship seafarers' workload: A case study of a real navigation experiment, *Ocean Engineering*, Vol. 300, 117346, ISSN 0029-8018, <https://doi.org/10.1016/j.oceaneng.2024.117346>.

19. Zhang, X. et al. (2026). Towards operational safety in maritime transportation: a neurophysiological workload measurement using deep learning, *Ocean Engineering*.
20. Volume 351, Part 2, (2026). 124399, ISSN 0029-8018, <https://doi.org/10.1016/j.oceaneng.2026.124399>.
21. Petrovskiy, A. (2025). Dynamic model for calculating navigator fatigue level – Predictive Fatigue Index. *Scientific Bulletin of the Kherson State Maritime Academy Vol 31*, pp. 199–208, <https://doi.org/10.33815/2313-4763.2025.2.31.199-208>.

Petrovskiy A. V. CONCEPTUAL DYNAMIC MODEL OF OPERATOR FUNCTIONAL STATE CONSIDERING THE INTERACTION OF PHYSIOLOGICAL, COGNITIVE, AND OPERATIONAL FACTORS WITH ML-BASED CORRECTION

This article proposes a conceptual hybrid dynamic model of the operator functional state in maritime transport systems, taking into account the interaction of physiological, cognitive, and operational factors. The relevance of the study is driven by the significant impact of the human factor on maritime safety, particularly the influence of fatigue accumulation and cognitive workload fluctuations on decision-making processes and the occurrence of accidents in complex and time-constrained navigation conditions. Despite extensive research in this domain, most existing approaches to operator state assessment consider these factors separately, and do not provide an integrated and dynamically evolving representation of their interaction, which significantly limits their applicability in real-world operational environments. The proposed model introduces a unified framework for describing the temporal evolution of the operator's functional state as a multidimensional construct that combines physiological fatigue, cognitive workload, and operational context variables. The model reflects the cumulative and nonlinear nature of fatigue development, the variability and sensitivity of cognitive load to task demands, and the influence of external factors such as traffic density, environmental conditions, and operational complexity. Particular attention is given to the dynamic coupling between these components, which enables capturing feedback effects and interdependencies that are critical for realistic modeling of human performance in maritime systems. A key feature of the approach is the integration of a machine learning-based correction mechanism into the analytical core of the model. Specifically, gradient boosting is employed to approximate residual errors of the base conceptual model, allowing the identification of complex nonlinear relationships and latent dependencies that cannot be explicitly formalized. This hybrid structure ensures a balance between interpretability and predictive capability, preserving the transparency of the model while enhancing its adaptability to empirical data. Although the model is formulated at a conceptual level, it provides a basis for further formalization and numerical implementation in simulation and decision-support environments. The proposed approach can be used as a foundation for intelligent decision support systems in maritime transport, contributing to improved situational awareness, adaptive workload management, and enhanced navigation safety through a more comprehensive and flexible evaluation of operator performance.

Key words: operator fatigue; PFI index; maritime safety; ML; gradient boosting.

© Петровський А. В.

Статтю прийнято до редакції 29.04.2026