

ВОЙТЮК АНДРІЙ

Національний університет «Львівська політехніка»

<https://orcid.org/0009-0007-6983-0378>e-mail: andrii.a.voitiuk@lpnu.ua**МАТВІЙЧУК ЯРОСЛАВ**

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0002-5570-182X>e-mail: yaroslav.m.matviychuk@lpnu.ua

ГЛИБОКЕ НАВЧАННЯ ДЛЯ АВТОМАТИЗОВАНОЇ ДІАГНОСТИКИ ПРИ ПОЛІТРАВМАХ: АНАЛІЗ СИГНАЛІВ ТА КЛІНІЧНІ ПЕРСПЕКТИВИ

Політравма, особливо за наявності черепно-мозкової травми (ЧМТ), залишається критичним викликом для екстреної медицини через необхідність швидкої діагностики та обмеження традиційних методів. Інвазивний моніторинг, нейровізуалізація та шкали оцінювання, як-от шкала коми Глазго (ШКТ), часто вимагають часу, ресурсів або недоступні на догоспітальному етапі. Сучасні досягнення в галузі глибокого навчання (ГН) у поєднанні з аналізом фізіологічних сигналів відкривають нові можливості для автоматизованої, неінвазивної діагностики, здатної підтримувати клінічні рішення в реальному часі.

У цьому огляді проаналізовано новітні підходи до застосування ГН для інтерпретації біомедичних сигналів з метою виявлення ЧМТ. На основі семи досліджень (2022–2024 рр.) розглянуто моделі, що використовують згорткові нейронні мережі (ЗНМ), довгі короткочасні пам'яті (ДКП), EEGNet (глибока нейронна мережа, спеціалізована для аналізу електроенцефалографічних (ЕЕГ) сигналів), U-Net (згорткова нейронна мережа з U-подібною архітектурою для сегментації зображень) та трансферне навчання. Деякі з них досягають AUROC (площа під кривою робочої характеристики приймача) понад 0.90. Системи BioscoreNet та aICP демонструють практичне застосування ГН для виявлення внутрішньочерепної гіпертензії та оцінки тяжкості травми на основі пасивно або стаціонарно зібраних сигналів (ЕЕГ, аудіо, вібраційних, гемодинамічних даних).

Особливу увагу надано інтерпретованості моделей (наприклад, через градієнтно-активоване картографування), мультисенсорному злиттю даних і ролі мобільних технологій у первинному сортуванні постраждалих. Обговорюються також обмеження: варіабельність сигналів, малі вибірки, відсутність стандартизації. У підсумку, ГН-орієнтований аналіз сигналів може стати основою для масштабованих, доступних та ефективних діагностичних рішень у веденні пацієнтів з політравмами. Подальша клінічна валідація дозволить інтегрувати ці технології в щоденну практику екстреної медицини.

Ключові слова: глибоке навчання; політравма; черепно-мозкова травма; автоматизована діагностика; неінвазивний моніторинг; нейронні мережі.

VOITIUK ANDRII, MATVIICHUK YAROSLAV

Lviv Polytechnic National University

DEEP LERNING FOR AUTOMATED DIAGNOSIS IN POLYTRAUMA: SIGNAL ANALYSIS AND CLINICAL PERSPECTIVES

Polytrauma, particularly when associated with traumatic brain injury (TBI), remains a critical challenge in emergency care due to the urgency of diagnosis and the limitations of conventional methods. Invasive monitoring, neuroimaging, and neurological scoring systems such as the Glasgow Coma Scale are often time-consuming, resource-intensive, or unavailable during pre-hospital triage. Recent advances in deep learning (DL), combined with physiological signal analysis, offer promising opportunities for automated, non-invasive diagnostics capable of supporting real-time clinical decision-making.

This review explores recent approaches to using DL for interpreting biomedical signals to detect TBI. Based on seven key studies published between 2022 and 2024, we analyze models built on convolutional neural networks (CNNs), long short-term memory (LSTM), EEGNet, U-Net, and transfer learning techniques. Several models achieve AUROC values exceeding 0.90. Systems such as BioscoreNet and aICP demonstrate practical applications for detecting intracranial hypertension and assessing injury severity using passive or bedside-acquired signals, including EEG, speech, extracranial waveforms, and mobile sensor data.

Special attention is given to model interpretability (e.g., Grad-CAM visualizations), multisensory data fusion, and the integration of AI tools into mobile triage and monitoring platforms. The review also outlines current challenges, including signal variability, small datasets, and the need for clinical standardization. Ultimately, DL-based signal analysis represents a significant step toward scalable, accessible, and efficient diagnostic solutions in polytrauma management. Further clinical validation will be essential to enable seamless integration of these technologies into routine emergency medical practice.

Keywords: deep learning; polytrauma; traumatic brain injury; automated diagnosis; non-invasive monitoring; neural networks.

Стаття надійшла до редакції / Received 29.05.2025

Прийнята до друку / Accepted 26.06.2025

Постановка проблеми

Політравма залишається однією з провідних причин летальності та інвалідності серед осіб працездатного віку, особливо в умовах надзвичайних ситуацій, дорожньо-транспортних пригод, бойових дій або техногенних катастроф. Особливу загрозу становлять випадки з ураженням центральної нервової системи, зокрема черепно-мозкові травми, які потребують негайної діагностики та прийняття клінічних рішень. Проте традиційні методи — комп'ютерна томографія, нейровізуалізація, шкали оцінювання стану свідомості

(наприклад, ШКГ) — часто є обмеженими в екстрених умовах через відсутність обладнання, потребу в спеціалізованому персоналі або тривалість обстеження.

У зв'язку з цим зростає потреба в розробці технологій, здатних забезпечити швидке, об'єктивне та масштабове виявлення критичних станів без інвазивного втручання. Одним з таких перспективних напрямів є застосування методів глибокого навчання до аналізу біомедичних сигналів, що можуть бути отримані за допомогою мобільних пристроїв, електроенцефалографії, аудіозаписів мовлення, або неінвазивних сенсорних систем.

Проблема, яку розглядає дана стаття, полягає у відсутності інтегрованого огляду сучасних підходів глибокого навчання до автоматизованої діагностики ЧМТ при політравмах на основі багатоканального аналізу сигналів. Таке узагальнення є актуальним для формування наукового підґрунтя майбутніх клінічних досліджень, створення мобільних експрес-діагностичних рішень та систем підтримки прийняття рішень у польових умовах.

Мета статті

Метою даної оглядової статті є систематизація та критичний аналіз сучасних наукових підходів до застосування методів глибокого навчання для автоматизованої діагностики черепно-мозкової травми у контексті політравми. Основна увага приділяється аналізу моделей, орієнтованих на обробку та інтерпретацію біомедичних сигналів — електроенцефалограм, аудіозаписів мовлення, позачерепних хвильових форм, а також даних мобільних сенсорів для виявлення та оцінки тяжкості ушкоджень з майбутньою підтримкою клінічних рішень.

Також розглянуто архітектури нейронних мереж, що використовуються для аналізу вищезгаданих даних, інструменти підвищення інтерпретованості моделей, сценарії їх клінічного застосування, можливості переносу даних для розширення навчальних баз, а також обмеження, що постають у контексті медичної практики. Стаття має на меті узагальнити наявні досягнення, виявити спільні проблеми й окреслити перспективи подальших досліджень для інтеграції таких рішень у догоспітальну та стаціонарну медичну допомогу.

Виклад основного матеріалу

Упродовж останніх років спостерігається активне зростання інтересу до використання методів глибокого навчання (ГН) для автоматизованої діагностики черепно-мозкових травм (ЧМТ), особливо в умовах невідкладної медичної допомоги. Методи глибокого навчання демонструють високу ефективність у вирішенні складних задач, пов'язаних з обробкою біомедичних сигналів для автоматизованої діагностики з метою виявлення, класифікації та прогнозування ступеня ураження мозку. Аналіз відібраних досліджень дозволяє узагальнити тенденції та результати за кількома ключовими напрямками: типи сигналів, архітектури моделей, інтерпретованість, клінічне застосування та обмеження.

Типи біомедичних сигналів, що використовуються у моделях глибокого навчання для діагностики ЧМТ

- Моделі глибокого навчання забезпечують обробку як традиційних медичних даних (ЕЕГ, зображення КТ), так і нових типів сигналів, які можна отримати у польових або амбулаторних умовах.
- ЕЕГ-сигнали: найбільш досліджене джерело, завдяки своїй доступності та чутливості до нейрофункціональних змін. При використанні даних з Temple EEG Corpus [1] для класифікації полідіагностики (норма, ЧМТ, інсульт), моделі глибокого навчання досягли AUROC=0.85, навіть без попереднього виділення ознак [2]. Продemonстровано ефективність переносного навчання між видами (моделі, натреновані на ЕЕГ мишей, адаптовано до людських даних), що критично важливо при обмеженості клінічної вибірки [3].
- Аудіосигнали мовлення: Проведено класифікацію легкої ЧМТ серед спортсменів за короткими аудіофрагментами, обробленими з використанням MFCC та моделі Bi-LSTM-A. Система досягла AUROC=0.904, доводячи ефективність мовної діагностики як маркера когнітивних порушень [4]. Це відкриває перспективу застосування акустичного аналізу в польових умовах.
- Позачерепні хвильові форми: Модель для неінвазивного прогнозування внутрішньочерепної гіпертензії (внутрішньочерепний тиск ≥ 15 мм рт. ст.) на основі даних хвильової форми, зібраних у відділеннях інтенсивної терапії. Архітектура з 10 млн параметрів, навчена на понад 270 годин даних з MIMIC-III (Medical Information Mart for Intensive Care, версія III), досягла точності понад 80% [5].
- Мобільні сенсорні дані: Розроблений фреймворк BioscoreNet, що обробляє дані акселерометрів, гіроскопів, барометрів зі смартфонів для виявлення ЧМТ. Модель із самоувагою та ДКП досягла збалансованої точності 90.2%, дозволяючи реалізувати пасивний моніторинг із мінімальним навантаженням на персонал [6].

Архітектури та методи глибокого навчання. Розглянуті дослідження демонструють широкий спектр моделей глибокого навчання:

- EEGNet — легка 3НМ-архітектура, спеціально оптимізована для ЕЕГ, є однією з ключових моделей, адаптованих до роботи з крос-суб'єктними даними [3].
- Рекурентні нейронні мережі (ДКП, Bi-LSTM-A) забезпечують збереження часової послідовності сигналів і використовуються у мовному аналізі [4], а також у сенсорному моніторингу [6].

- Згорткові нейронні мережі використовуються для обробки як структурованих зображень (КТ, МРТ), так і одновимірних сигналів (ЕЕГ). ЗНМ забезпечує виявлення мікроконтузій на КТ-сканах із високою кореляцією з тяжкістю ЧМТ [7].
- U-Net та гібридні моделі застосовуються для просторово-часової сегментації нейровізуальних даних [8].

Таблиця 1

Порівняння розглянутих моделей глибокого навчання

Тип сигналу	Архітектура моделі	AUROC / Точність	Особливості
КТ / медичні зображення	ЗНМ	Не зазначено	Огляд ЗНМ для прогнозу наслідків
ЕЕГ (люди/миші)	EEGNet, Перенесення навчання	Переносимість підтверджено	Перенос даних між видами
ЕЕГ	ЗНМ, градієнтно-активоване картографування	AUROC ≈ 0.85	Безознакова модель + градієнтно-активоване картографування
Мовлення / аудіо	Bi-LSTM-A	AUROC = 0.904	Мовна діагностика легкої ЧМТ
Мульти / КТ / клінічні	Узагальнено (ГН, ШІ)	До 95.6% (прогноз смертності)	ШІ у реабілітації та клініці
Хвильові дані (позачерепні)	ЗНМ (10M параметрів)	AUROC = 0.80	Неінвазивна альтернатива внутрішньочерепному тиску
Мобільні сенсори	Self-attention + ДКП	Збалансована точність = 90.2%	Bioscore, пасивний моніторинг

Інтерпретованість моделей та клінічна валідація

Інтерпретованість є критичним аспектом медичних систем глибокого навчання. Зовнішня валідація проведена на даних клініки Mount Sinai (2020–2022), де система для виявлення гіпертензії показала AUROC=0.80 при когортах понад 270 годин записів [5].

Застосування градієнтно-активованого картографування для візуалізації важливих фрагментів ЕЕГ, слугують основою класифікації [7]. Це дозволяє лікарю не лише прийняти або відхилити рішення, але й зрозуміти його причини.

Клінічні сценарії застосування та обмеження

Моделі глибокого навчання демонструють перспективу в кількох практичних сценаріях:

- Спортивна медицина та самодіагностика дозволяє проводити первинну діагностику в польових умовах з використанням неспеціалізованих пристроїв [4].
- Інтенсивна терапія дозволяє знизити потребу в інвазивному моніторингу [5].
- Догоспітальне сортування дає змогу фельдшеру або рятувальнику мати об'єктивні критерії для направлення [6].

Водночас спостерігаються спільні обмеження:

- відсутність масштабних датасетів;
- обмежена узагальнюваність моделей при переході на нові пристрої/популяції;
- складність інтеграції модулів глибокого навчання у сертифіковані медичні платформи.

Таблиця 2

Порівняння розглянутих моделей глибокого навчання

Параметр	Традиційна діагностика (СТ, ШКГ)	Діагностика з глибоким навчанням (ЕЕГ, моб. сенсори, аудіо)
Метод дослідження	Оцінка за шкалою ШКГ, КТ	Глибоке навчання на сигналах/звуках
Тип даних	Зображення, клінічні ознаки	ЕЕГ, аудіо, моб. сенсори
Точність при легкій травмі	Низька	Висока (до 90–94%)
Необхідність спеціального обладнання	Так (КТ, госпітальні умови)	Ні (портативні сенсори, смартфон)
Час до отримання результату	30 хв – 1 год	<10 хв
Можливість дистанційного моніторингу	Ні	Так
Інтерпретація результатів	Лікар-експерт	Автоматизована
Вартість	Висока	Низька/середня
Адаптованість до польових умов	Низька	Висока

Висновки

Результати проведеного огляду свідчать про високий науковий та практичний потенціал застосування методів глибокого навчання для автоматизованої діагностики черепно-мозкової травми (ЧМТ) у контексті політравми. Моделі глибокого навчання продемонстрували здатність ефективно обробляти різні типи біомедичних сигналів — від ЕЕГ і аудіозаписів до хвильових форм і сенсорних даних зі смартфонів. Досягнуто високих показників точності (AUROC>0.90) у задачах класифікації ступеня ураження, виявлення внутрішньочерепної гіпертензії та оцінки неврологічного стану пацієнтів.

Особливої уваги заслуговує розвиток мобільних та неінвазивних рішень, які можуть використовуватись у догоспітальних або ресурсно-обмежених умовах. Інтеграція таких систем у польову медицину, швидку допомогу або первинну тріажну сортувальну допомогу має потенціал значно підвищити оперативність надання допомоги постраждалим з ЧМТ.

Однак існує низка важливих викликів:

- обмежена доступність великих відкритих біомедичних датасетів;
- варіабельність сигналів між пацієнтами та умовами запису;
- складність клінічної інтеграції моделей, які є складними у тлумаченні для медичних працівників без технічної підготовки;

- питання етичності, приватності та нормативного регулювання впровадження ШІ в медицину.

У перспективі подальші дослідження мають бути зосереджені на:

- мультицентровій клінічній валідації моделей;
- створенні стандартизованих протоколів збору сигналів;
- поєднанні ГН з класичними методами (гібридні системи);
- розробці інтерпретованих, надійних та регульованих інструментів для підтримки клінічних рішень.

Таким чином, глибоке навчання відкриває нові горизонти для розвитку швидких, масштабованих та об'єктивних методів діагностики ЧМТ, які можуть стати важливим компонентом системи невідкладної медичної допомоги у XXI столітті.

Література

1. Obeid, I., & Picone, J. (2016). The Temple University Hospital EEG Corpus. *Neural Engineering Data Consortium*. Retrieved from https://www.isip.piconepress.com/projects/tuh_eeg/html/downloads.shtml
2. Caiola, M., Babu, A., & Ye, M. (2023). EEG classification of traumatic brain injury and stroke from a nonspecific population using neural networks. *PLOS Digital Health*, 2(7), e0000282. <https://doi.org/10.1371/journal.pdig.0000282>
3. Vishwanatha, M., Cao, S., Dutta, N., Rahmani, A. M., Lim, M. M., & Cao, H. (2023). Reducing intraspecies and interspecies covariate shift in traumatic brain injury EEG of humans and mice using transfer Euclidean alignment. *arXiv*. <https://arxiv.org/abs/2310.02398>
4. Wall, C., Powell, D., Young, F., Zynda, A. J., Stuart, S., Covassin, T., & Godfrey, A. (2022). A deep learning-based approach to diagnose mild traumatic brain injury using audio classification. *PLOS ONE*, 17(9), e0274395. <https://doi.org/10.1371/journal.pone.0274395>
5. Gulamali, F., Jayaraman, P., Sawant, A. S., Desman, J., Fox, B., Chang, A., ... & Nadkarni, G. N. (2024). Derivation, external and clinical validation of a deep learning approach for detecting intracranial hypertension. *NPJ Digital Medicine*, 7, Article 233. <https://doi.org/10.1038/s41746-024-01227-0>
6. Asani, F., Patel, B., Srikanthan, S., & Agu, E. (2022). BioscoreNet: Traumatic brain injury (TBI) detection using a multimodal self-attention fusion neural network and a passive bioscore monitoring framework from smartphone sensor data. *Smart Health*, 27, 100352. <https://doi.org/10.1016/j.smhl.2022.100352>
7. Zinnel, L., & Bentil, S. A. (2023). Application of convolutional neural networks for traumatic brain injury classification and outcome prediction: A review. *Health Sciences Review*, 9, 100126. <https://doi.org/10.1016/j.hsr.2023.100126>
8. Orenuga, S., Jordache, P., Mirzai, D., Monteros, T., Gonzalez, E., Madkoor, A., ... & Etienne, M. (2025). Traumatic brain injury and artificial intelligence: Shaping the future of neurorehabilitation—A review. *Life*, 15(3), 424. <https://doi.org/10.3390/life15030424>

References

1. Obeid, I., & Picone, J. (2016). The Temple University Hospital EEG Corpus. *Neural Engineering Data Consortium*. Retrieved from https://www.isip.piconepress.com/projects/tuh_eeg/html/downloads.shtml
2. Caiola, M., Babu, A., & Ye, M. (2023). EEG classification of traumatic brain injury and stroke from a nonspecific population using neural networks. *PLOS Digital Health*, 2(7), e0000282. <https://doi.org/10.1371/journal.pdig.0000282>
3. Vishwanatha, M., Cao, S., Dutta, N., Rahmani, A. M., Lim, M. M., & Cao, H. (2023). Reducing intraspecies and interspecies covariate shift in traumatic brain injury EEG of humans and mice using transfer Euclidean alignment. *arXiv*. <https://arxiv.org/abs/2310.02398>
4. Wall, C., Powell, D., Young, F., Zynda, A. J., Stuart, S., Covassin, T., & Godfrey, A. (2022). A deep learning-based approach to diagnose mild traumatic brain injury using audio classification. *PLOS ONE*, 17(9), e0274395. <https://doi.org/10.1371/journal.pone.0274395>

5. Gulamali, F., Jayaraman, P., Sawant, A. S., Desman, J., Fox, B., Chang, A., ... & Nadkarni, G. N. (2024). Derivation, external and clinical validation of a deep learning approach for detecting intracranial hypertension. *NPJ Digital Medicine*, 7, Article 233. <https://doi.org/10.1038/s41746-024-01227-0>
6. Asani, F., Patel, B., Srikanthan, S., & Agu, E. (2022). BioscoreNet: Traumatic brain injury (TBI) detection using a multimodal self-attention fusion neural network and a passive bioscore monitoring framework from smartphone sensor data. *Smart Health*, 27, 100352. <https://doi.org/10.1016/j.smhl.2022.100352>
7. Zinnel, L., & Bentil, S. A. (2023). Application of convolutional neural networks for traumatic brain injury classification and outcome prediction: A review. *Health Sciences Review*, 9, 100126. <https://doi.org/10.1016/j.hsr.2023.100126>
8. Orenuga, S., Jordache, P., Mirzai, D., Monteros, T., Gonzalez, E., Madkoor, A., ... & Etienne, M. (2025). Traumatic brain injury and artificial intelligence: Shaping the future of neurorehabilitation—A review. *Life*, 15(3), 424. <https://doi.org/10.3390/life15030424>