

## ІНТЕЛЕКТУАЛЬНА СИСТЕМА КЛАСИФІКАЦІЇ АУДІОФАЙЛІВ

*Анотація. Інтенсивне збільшення обсягу цифрових музичних даних актуалізує питання їх структуризації з метою полегшення доступу для користувачів. Жанрова класифікація є одним із ефективних засобів організації музичних творів, що сприяє персоналізованому вибору композицій і генерації релевантних рекомендацій. Метою даного дослідження є аналіз ефективності поєднання різних аудіоознак для реалізації жанрової класифікації із застосуванням багатопараметричного перцептрона та визначення шляхів покращення точності розпізнавання. Розглянуто методи розрахунку часових і частотних акустичних характеристик, реалізовано автоматичний підбір гіперпараметрів за допомогою бібліотеки Optuna, проведено навчання і тестування моделі на основі датасету GTZAN. Запропоновано механізм покращення якості класифікації шляхом додаткової обробки результатів передбачення нейромережі за допомогою методів жорсткого, м'якого та рангового голосування за методом Борда. Отримані результати демонструють істотне підвищення точності класифікації у порівнянні з базовими підходами.*

*Ключові слова: штучний інтелект, нейронні мережі, машинне навчання, інтелектуальна система, розв'язок задачі класифікації, метрики якості розпізнавання, оптимізація параметрів моделі, методи ансамблевого голосування, аудіоознаки, музичні жанри.*

**Постановка проблеми.** Стрімке зростання обсягу цифрових музичних композицій суттєво ускладнює задачу ефективного використання цього величезного масиву культурного надбання людства. Музичні сервіси повинні не тільки забезпечувати багатопараметричний пошук, надаючи можливість користувачам обирати улюблені композиції. Вкрай важливою функцією музичних платформ є збагачення музичного досвіду слухачів шляхом представлення нових творів для ознайомлення. При цьому система підбірки контенту має не просто пропонувати прослухати найбільш популярні твори, що користуються попитом у багатьох користувачів. Не варто також вдаватись і до просування менш популярних з метою підвищення їх рейтингу. Якісна рекомендаційна система залучає індивідуальні смаки кожного окремого користувача, пропонуючи саме ті твори, які з високою вірогідністю будуть позитивно сприйняті. Для цього важливо брати до уваги як персональну історію прослуховування, так і перелік композицій, які подобаються іншим користувачам зі схожими музичними смаками. Одним із поширених підходів до вирішення цих проблем є жанрова класифікація. Вона забезпечує можливість структурувати масив музичної інформації для зручного доступу, що дає змогу

слухачам обирати твори відповідно до їх індивідуальних музичних вподобань. Крім того, жанровий поділ створює умови для формування персоніфікованих профілів смаків всіх користувачів для надання персоналізованих рекомендацій щодо нових композицій, враховуючи особисті музичні преференції.

**Аналіз останніх досліджень і публікацій.** Для розв'язання задач жанрової класифікації активно застосовуються сучасні засоби штучного інтелекту. Серед численних підходів машинного навчання особливої популярності набули різні архітектури штучних нейронних мереж, тренування яких здійснюється на основі різноманітних аудіоознак та їхніх комбінацій.

Результативність навчання багатосарового перцептрона (MLP), рекурентних нейронних мереж (RNN) та згорткових нейронних мереж (CNN) на основі мел-частотних кепстральних коефіцієнтів (MFCCs) має важливе значення для підвищення точності автоматичної класифікації аудіоданих [1]. Для зазначених архітектур продемонстровано досягнення точності на тестовій вибірці 60 %, 67 % та 74 %.

Вибір функції активації істотно впливає на процес тренування нейронної мережі. Розглянувши ефективність застосування наступних функцій активації: Sigmoid, Tanh, ReLU, Leaky ReLU, ELU при навчанні MLP, RNN та CNN, виявлено, що найкращі результати спостерігаються при використанні Leaky ReLU, забезпечуючи точність 56 %, 66 % та 74 % для MLP, RNN та CNN відповідно [2]. Така продуктивність пояснюється здатністю Leaky ReLU зберігати від'ємні значення градієнта, масштабуючи їх із малим коефіцієнтом, на відміну від ReLU, яка повністю їх занулює.

Комбінована архітектура CNN+RNN, навчання якої здійснювалося на основі трьох типів спектрограм: звичайної спектрограми, отриманої в результаті застосування короткочасного перетворення Фур'є (STFT); мел-спектрограми, яка формується шляхом масштабування частот STFT за мел-шкалою, що моделює особливості акустичного сприйняття людини; CQT-спектрограми (Constant-Q Transform), яка забезпечує адаптивний розмір частотних бінів завдяки використанню постійного коефіцієнта Q, продемонструвала близькі значення точності класифікації на рівні 85 % при використанні спектрограм STFT та CQT [3].

Застосувавши у якості вхідних даних два типи аудіоознак: MFCCs та мел-спектрограм для навчання чотирьох комбінованих архітектур: CNN+LSTM (мережа з довготривалою короткочасною пам'яттю), CNN+BiLSTM (двонаправлений варіант LSTM), CNN+GRU (керована рекурентна одиниця, спрощений варіант LSTM), та CNN+BiGRU (двонаправлена модифікація GRU), було встановлено, що найвищу ефективність продемонструвала архітектура CNN+BiGRU, забезпечивши точність 76 % при використанні MFCCs та 89 % – при використанні мел-спектрограм [4].

**Мета дослідження.** Проаналізувати ефективність поєднання різних видів аудіоознак для реалізації жанрової класифікації аудіофайлів із застосуванням багатосарового перцептрона та визначити шляхи покращення точності розпізнавання.

**Основний матеріал дослідження.** Для досягнення мети було розроблено програмне забезпечення мовою Python, залучаючи фреймворк PyTorch для створення мо-

делей нейронних мереж, бібліотеки Scikit-learn для розрахунку статистичних метрик та Matplotlib для графічної візуалізації процесу тренування та результатів класифікації.

Архітектурним рішенням для нейронної мережі обрано багатошаровий перцептрон (MLP) [5], у якому на прихованих шарах використано активаційну функцію PReLU (Parametric ReLU), основною перевагою якої є не лише збереження від'ємного градієнта, а й можливість автоматичного налаштування параметра масштабування негативної частини функції під час навчання нейронної мережі.

Для обчислення вихідних значень 10 нейронів вихідного шару використовується функція Softmax, яка повертає ймовірності належності до кожного з 10 класів [6]. У ролі функції втрат застосовується категоріальна крос-ентропія [7].

У якості вхідних даних було використано датасет GTZAN [8], який містить 1000 аудіофрагментів тривалістю 30 секунд. Вони рівномірно розподілені серед 10 наступних класів: 9 популярних жанрів (блюз, кантрі, диско, хіп-хоп, джаз, метал, поп, реггі, рок) та окрема категорія класичної музики, що поєднує низку академічних жанрів (симфонію, концерт, сонату тощо). Хоча з часів античності створено колосальну кількість класичних музичних творів, проте модель навчається і використовується лише на обмеженому наборі поширених класичних поліфонічних композицій, що представлені в електронних базах даних. Усі файли збережено у форматі WAV (моно, частота дискретизації 22050 Hz, розрядність 16 bit).

Для кожного фрагмента обчислено наступний набір ознак як на рівні всього 30-секундного запису, так і за його поділом на десять 3-секундних сегментів:

– **Chroma Features** – хроматичні ознаки, або хрома-функції, відображають енергетичний розподіл частот аудіосигналу в межах октав, групуючи їх за висотою звуку (хроматичністю). Оскільки стандартна шкала частот має логарифмічну структуру, частоти, що відрізняються на октаву (наприклад, 220 Гц, 440 Гц, 880 Гц), сприймаються людським вухом як однакові ноти. Хрома-функції представляють спектральну енергію у вигляді 12-бінного вектора, де кожен бін відповідає одному з 12 півтонів музичної гами, незалежно від октави.

– **Root Mean Square Energy (RMSE)** – середньоквадратична енергія – є мірою загальної потужності або інтенсивності сигналу:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

де  $N$  – загальна кількість точок у сигналі,  $x_i$  – амплітуда сигналу в момент часу  $i$ .

– **Spectral Centroid (SC)** – спектральний центроїд – характеризує центр мас спектра сигналу, визначаючи середню частоту, зважену за амплітудами, і відображає розподіл енергії в спектрі:

$$SC = \frac{\sum_{n=1}^N f_n |X(f_n)|}{\sum_{n=1}^N |X(f_n)|} \quad (2)$$

де  $N$  – кількість частотних бінів,  $f_n$  – частота  $n$ -го біну спектра,  $|X(f_n)|$  – амплітуда спектра на частоті  $f_n$ .

– **Spectral Bandwidth (SB)** – ширина спектра – є мірою розподілу частот у спектрі сигналу, оцінює, наскільки амплітуди частот відхиляються від середнього значення спектра:

$$SB = \sqrt{\frac{\sum_{n=1}^N (f_n - SC)^2 |X(f_n)|^2}{\sum_{n=1}^N |X(f_n)|^2}} \quad (3)$$

де  $N$  – кількість частотних бінів,  $f_n$  – частота  $n$ -го біну спектра,  $|X(f_n)|$  – амплітуда спектра на частоті  $f_n$ ,  $SC$  – спектральний центроїд.

– **Spectral Rolloff** – спектральний ролоф – це параметр, що визначає частоту, нижче якої сконцентрований заданий відсоток (наприклад, 85%) загальної енергії спектра звукового сигналу:

$$Rolloff = \min\{f_n \mid \sum_{k=1}^n |X(f_k)|^2 \geq \alpha \sum_{k=1}^N |X(f_k)|^2\} \quad (4)$$

де  $N$  – кількість частотних бінів,  $f_n$  – частота  $n$ -го біну спектра,  $|X(f_k)|$  – амплітуда спектра на частоті  $f_k$ ,  $\alpha$  – порогове значення (зазвичай вибирають  $\alpha=0.85$ ),  $n$  – номер біну спектра, до якого накопичена певна частка сумарної потужності спектра, що відповідає обраному пороговому значенню  $\alpha$ .

– **Zero Crossing Rate (ZCR)** – частота перетину нуля – це характеристика аудіо-сигналу, що визначає кількість змін знаку сигналу (перетинів нульової осі) за одиницю часу.

– **Harmonic Component (HC)** – гармонійна складова – це частина сигналу, що характеризується тривалими, плавними гармонічними звуками, типовими для мелодичних та гармонічних інструментів (наприклад, вокал, струнні або духові інструменти). Визначається шляхом застосування медіанного фільтра вздовж часової осі.

– **Percussive Component (PF)** – перкусивна складова – це частина сигналу, що містить короткі, різкі звуки, типові для ударних інструментів (наприклад, барабани, хай-хети тощо). Розраховується за допомогою медіанного фільтра вздовж частотної осі.

– **Tempo (BPM – beats per minute)** – темп (швидкість ударів за хвилину) – показник, що вимірює швидкість виконання музичного твору та характеризує його ритмічний і динамічний характер.

– **Mel-Frequency Cepstral Coefficients (MFCCs)** – мел-частотні кепстральні коефіцієнти – це набір коефіцієнтів, які моделюють тембральні характеристики аудіо-сигналу [9]. Для аналізу розраховано перші 20 коефіцієнтів.

Для кожної з перелічених ознак, за винятком темпу, були обчислені середнє значення та дисперсія.

Навчання моделі здійснено на векторі ознак розмірністю 57, який містить усі розглянуті аудіоознаки, обчислені для 3-секундних фрагментів композицій. Розподіл даних на навчальний, валідаційний та тестовий набори проведено у співвідношенні 7:1:2 із застосуванням стратифікованої вибірки, що зберігає пропорції класів у кожному наборі, для підвищення узагальнюючої здатності моделі. Важливо зазначити, що всі 10 фрагментів одного музичного твору повинні належати до одного й того ж набору, аби уникнути «витоку інформації» між навчальним і тестовим наборами. Порушення цього принципу призведе до того, що модель тестуватиметься на даних, які частково вона вже бачила під час тренування, що спотворює оцінку її узагальнюючої здатності.

Оцінювання якості моделі виконано за такими показниками: точність (accuracy), влучність (precision), повнота (recall), F1-метрика (F1-score) та матриця помилок (confusion matrix).

Для автоматизованого підбору гіперпараметрів було використано модуль Optuna, який реалізує не лише випадковий пошук або перебір за фіксованим сітковим планом, а застосовує інтелектуальну стратегію оптимізації на основі байєсівського підходу – зокрема, методу TPE (Tree-structured Parzen Estimator) – оцінювач Парзена, що використовує деревоподібну структуру оцінки розподілу ймовірностей.

Для надання моделі гнучкості було реалізовано динамічну архітектуру багатошарового перцептрона, яка дозволяє змінювати кількість прихованих шарів і нейронів у кожному з них. Здійснено 100 експериментів із варіюванням наступних гіперпараметрів: кількість прихованих шарів – від 1 до 5, кількість нейронів у кожному прихованому шарі – від 16 до 128, коефіцієнт навчання – у діапазоні від 0.00001 до 0.01, кількість епох – від 10 до 50.

На рисунку 1 наведено значення функції втрат і точності моделі для кожного з проведених експериментів.

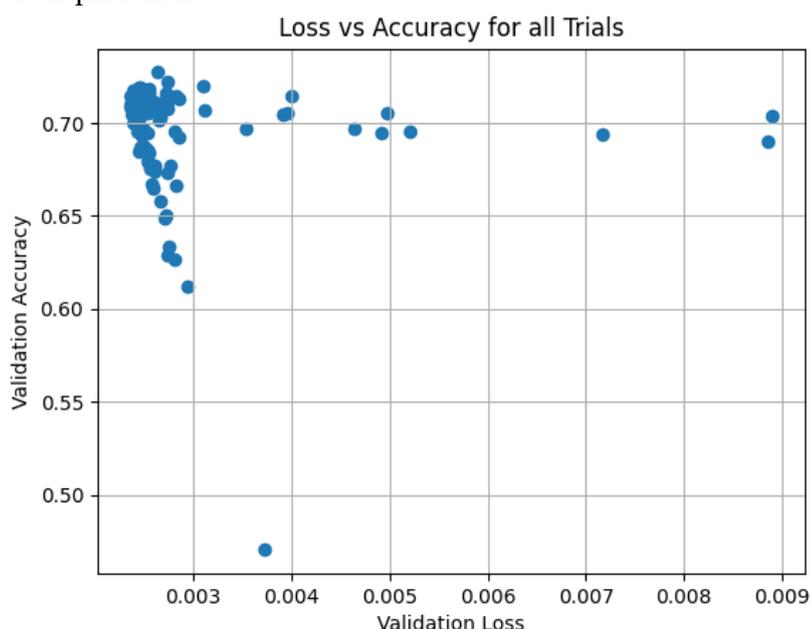


Рисунок 1 – Значення функції втрат і точності моделі на кожному з етапів підбору гіперпараметрів модулем Optuna

Отримано такі оптимальні гіперпараметри нейронної мережі: кількість нейронів у двох прихованих шарах – (101, 128), крок навчання – 0.00068, кількість епох – 43.

На рисунку 2 представлено архітектуру моделі, сформовану відповідно до підібраних параметрів.

Layer (type:depth-idx)	Input Shape	Output Shape	Param #
Sequential	[1, 57]	[1, 10]	--
└Linear: 1-1	[1, 57]	[1, 101]	5,858
└BatchNorm1d: 1-2	[1, 101]	[1, 101]	202
└PReLU: 1-3	[1, 101]	[1, 101]	1
└Linear: 1-4	[1, 101]	[1, 128]	13,056
└BatchNorm1d: 1-5	[1, 128]	[1, 128]	256
└PReLU: 1-6	[1, 128]	[1, 128]	1
└Linear: 1-7	[1, 128]	[1, 10]	1,290

Total params: 20,664  
 Trainable params: 20,664  
 Non-trainable params: 0  
 Total mult-adds (Units.MEGABYTES): 0.02

Input size (MB): 0.00  
 Forward/backward pass size (MB): 0.01  
 Params size (MB): 0.08  
 Estimated Total Size (MB): 0.09

Рисунок 2 – Архітектура нейромережі з підібраними оптимальними параметрами

На рисунку 3 відображено зміни значень функції втрат і точності для тренувальної та валідаційної вибірок у процесі навчання моделі.



Рисунок 3 – Динаміка зміни функції втрат і точності під час тренування мережі

Як видно з графіка, після 21 епохи спостерігається значне зростання функції втрат на валідаційній вибірці, що свідчить про початок перенавчання моделі. Тому доцільно зупинити навчання саме на цій епосі для уникнення вказаного ефекту.

На рисунку 4 наведено результати класифікації навченою моделлю для 3-секундних фрагментів аудіо.

Для агрегування результатів 10 передбачень нейронної мережі по кожному музичному твору застосовувалися наступні методи ансамблевого голосування:

– **Hard Voting (жорстке голосування)** – кожен класифікатор робить окремий прогноз, а остаточне рішення приймається на основі більшості голосів.

– **Soft Voting (м'яке голосування)** – враховуються ймовірності належності зразка до кожного класу, що генеруються класифікаторами; підсумовуються ймовірності для кожного класу, після чого обирається клас із найбільшою сумарною ймовірністю [10].

– **Borda Count (метод Борда)** – специфічний вид рангового голосування, у якому кожному класу призначаються бали залежно від його позиції у ранжованому списку кожного класифікатора. Клас із найбільшою сумою балів від усіх класифікаторів обирається як остаточний прогноз [11].

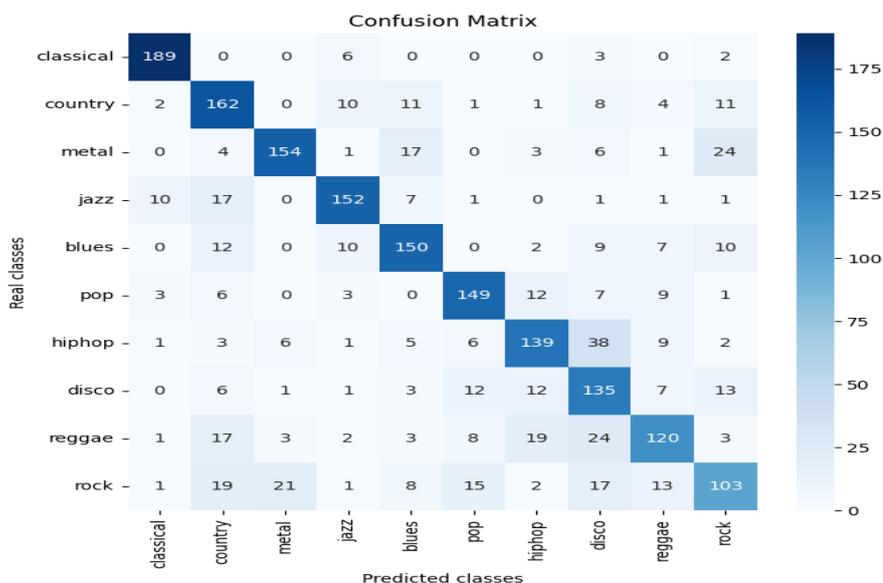


Рисунок 4 – Матриця помилок класифікації нейронної мережі

Рисунок 5 ілюструє розподіл коректних та некоректних передбачень, отриманих методом голосування Борда для кожного класу окремо. Твори класичної музики та жанру кантрі були класифіковані з високою точністю, тоді як точність класифікації жанрів рок, реггі та хіп-хоп виявилась нижчою, що може бути пояснено їх більшою варіативністю.

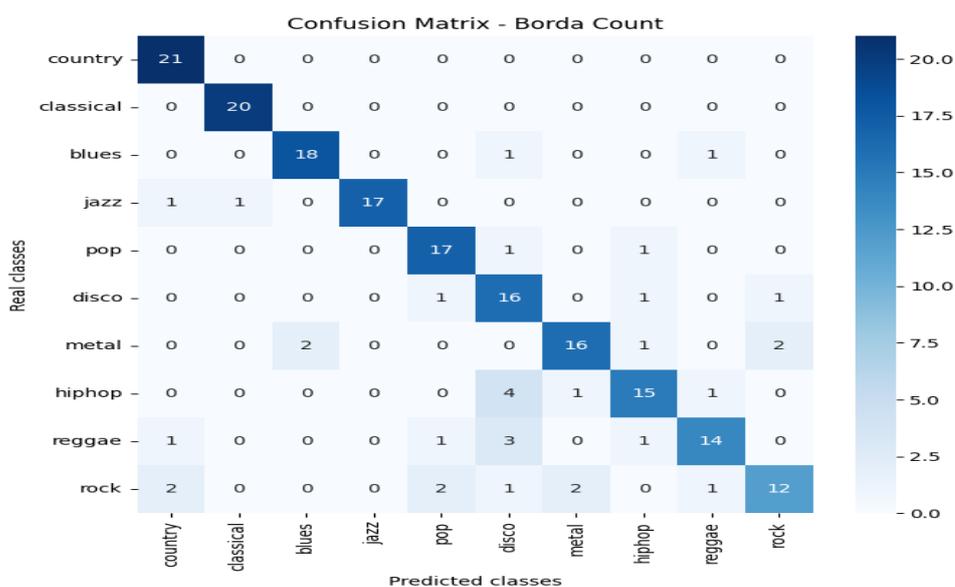


Рисунок 5 – Матриця помилок голосування методом Борда

У таблиці 1 наведені метрики якості передбачень як безпосередньо для багатошарового перцептронну (MLP), так і для поєднань його результатів із відповідними методами ансамблевого голосування.

Таблиця 1

Метрики якості передбачень моделей

Model	Accuracy	Precision	Recall	F1-score
MLP	72.7%	73.2%	72.7%	72.7%
MLP + Hard Voting	81%	81.7%	81%	80.9%
MLP + Soft Voting	82%	82.6%	82%	81.8%
MLP + Borda Count	83%	83.7%	83%	82.8%

**Висновки.** У роботі розглянуто методи розрахунку часових та частотних аудіоознак і встановлено, що поєднання навіть невеликої кількості таких ознак із використанням лише їх середніх значень та дисперсій у якості вхідних даних для тренування нейромережі забезпечує досить високі результати жанрової класифікації. Це досягається навіть при застосуванні відносно простої архітектури нейронної мережі – перцептронну з двома прихованими шарами та невеликою кількістю нейронів у них. Автоматичний підбір гіперпараметрів мережі здійснено за допомогою модуля Optuna, після чого проведено навчання та тестування моделі на наборі музичних даних GTZAN. Поділ 30-секундних музичних уривків на 10 частин для тренування нейромережі, а також подальше об'єднання передбачень для кожного фрагмента з використанням методів жорсткого, м'якого голосування та рангового голосування методом Борда дозволили суттєво підвищити точність класифікації.

#### ЛІТЕРАТУРА

1. Jain S., Yadav S., Prabir P., Sundar S. Music information retrieval and classification using deep learning. International Research Journal of Engineering and Technology (IRJET), 06 June 2021, Vol. 08, P. 1059-1066.
2. Hu Y., Mogos G. Music genres classification by deep learning. Indonesian Journal of Electrical Engineering and Computer Science, [S.l.] , February 2022, Vol. 25, No. 2, P. 1186-1198. DOI: <https://doi.org/10.11591/ijeecs.v25.i2.pp1186-1198>
3. Umale A., Mehul, Bhandw P., Bagwan S., Patil S.M. Music genre classification. International Journal of Advanced Research in Science, Communication and Technology (IJARSCT), 13 May 2023, Vol. 3, P. 414-425.
4. Ashraf M., Abid F., Din I.U., Rasheed J., Yesiltepe M., Yeo S.F., Ersoy M.T. A Hybrid CNN and RNN variant model for music classification. Applied Sciences, 2023, 13(3), 1476. DOI: <https://doi.org/10.3390/app13031476>
5. Ткаліченко С.В. Штучні нейронні мережі: навч. посіб. Кривий Ріг: Державний університет економіки і технологій, 2023. 150 с.
6. Субботін С.О. Нейронні мережі: теорія та практика: навч.посіб. Житомир, 2020.184с.
7. Nielsen M. Neural networks and deep learning. 2013. URL: <http://neuralnetworksanddeeplearning.com>

8. Tzanetakis G., Cook P. Musical genre classification of audio signals. IEEE Transactions on Speech and Audio Processing, July 2002, Vol. 10, No. 5. URL: <https://www.cs.cmu.edu/~gtzan/work/pubs/tsap02gtzan.pdf>
9. Zheng J., Oussalah M. Automatic system for music genre classification. 2006. URL: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=342e83b5272b701b225b289e817bb8d92db0fad2>
10. Simic M., Aibin M. Hard vs. soft voting classifiers. 28 February 2025. URL: <https://www.baeldung.com/cs/hard-vs-soft-voting-classifiers>
11. Drotar P., Gazda M., Vokorokos L. Ensemble feature selection using election methods and ranker clustering. Information Sciences, 2019, Vol. 480, P. 365-380.

#### REFERENCES

1. Jain, S., Yadav, S., Prabir, P., & Sundar, S. (2021, June 6). Music information retrieval and classification using deep learning. International Research Journal of Engineering and Technology (IRJET), Vol. 08, P. 1059-1066.
2. Hu, Y., & Mogos, G. (2022, February). Music genres classification by deep learning. Indonesian Journal of Electrical Engineering and Computer Science, [S.l.], Vol. 25, No. 2, P. 1186-1198. DOI: <https://doi.org/10.11591/ijeecs.v25.i2.pp1186-1198>
3. Umale, A., Mehul, Bhandw, P., Bagwan, S., & Patil, S. M. (2023, May 13). Music genre classification. International Journal of Advanced Research in Science, Communication and Technology (IJARSCT), Vol. 3, P. 414-425.
4. Ashraf, M., Abid, F., Din, I.U., Rasheed, J., Yesiltepe, M., Yeo, S.F., & Ersoy, M.T. (2023). A Hybrid CNN and RNN variant model for music classification. Applied Sciences, 13(3), 1476. DOI: <https://doi.org/10.3390/app13031476>
5. Tkalychenko, S.V. (2023). Shtuchni neyronni merezhi [Artificial neural networks]. Kryvyi Rih: Derzhavnyi universytet ekonomiky i tekhnolohii [in Ukrainian].
6. Subbotin, S.O. (2020). Neyronni merezhi: teoriia ta praktyka [Neural networks: theory and practice]. Zhytomyr [in Ukrainian].
7. Nielsen M. (2013). Neural networks and deep learning. URL: <http://neuralnetworksanddeeplearning.com>
8. Tzanetakis, G., & Cook, P. (2002, July). Musical genre classification of audio signals. IEEE Transactions on Speech and Audio Processing, Vol. 10, No. 5. URL: <https://www.cs.cmu.edu/~gtzan/work/pubs/tsap02gtzan.pdf>
9. Zheng, J., & Oussalah, M. (2006). Automatic system for music genre classification. URL: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=342e83b5272b701b225b289e817bb8d92db0fad2>
10. Simic, M., & Aibin, M. (2025, February 28). Milos Simic, Michal Aibin. Hard vs. soft voting classifiers. URL: <https://www.baeldung.com/cs/hard-vs-soft-voting-classifiers>
11. Drotar, P., Gazda, M., & Vokorokos, L. (2019). Peter Drotar, Matej Gazda, Liberios Vokorokos. Ensemble feature selection using election methods and ranker clustering. Information Sciences, Vol. 480, P. 365-380.

Received 23.01.2026.

Accepted 28.01.2026.

***Intelligent audio file classification system***

*The continuously increasing volume of music compositions highlights the need for effective organization to ensure convenient user access. Genre classification is one of the common approaches, enabling listeners to select tracks according to their individual preferences and receive automated recommendations for new content. The literature review of previous studies demonstrated that different types of artificial neural network architectures are used for classification, utilizing various audio features and their combinations for training. Using mel-frequency cepstral coefficients (MFCCs) as input data revealed the advantages of convolutional neural networks (CNN) over multilayer perceptrons (MLP) and recurrent neural networks (RNN). Evaluating activation functions such as Sigmoid, Tanh, ReLU, Leaky ReLU, ELU on MLP, RNN and CNN showed that Leaky ReLU achieved the best performance due to its ability to retain scaled negative gradients, unlike ReLU, which just zeros them out. A combined CNN+RNN architecture provided great results using MFCCs and spectrograms as input data. This study aims to analyze the effectiveness of combining various types of audio features for genre classification using a multilayer perceptron, as well as to explore methods for improving classification accuracy. Time-domain and frequency-domain audio features were examined. The neural network was trained and tested on the GTZAN dataset, containing 1000 audio samples with duration of 30 seconds, 100 samples for each of 10 genres. The hyperparameters were automatically optimized using the Optuna framework, which applies intelligent search based on Tree-structured Parzen Estimator. Furthermore, a post-processing mechanism based on hard voting, soft voting, and the Borda count method was introduced. Experimental results demonstrate that the proposed ensemble approach significantly enhances the classification accuracy compared to the baseline model.*

*Keywords: artificial intelligence, neural networks, machine learning, intelligent system, solving classification task, recognition quality metrics, model parameters optimization, ensemble voting methods, audio features, musical genres.*

**Сулейманов Євгеній Сагірович** – аспірант кафедри інженерії програмного забезпечення та інформаційних технологій Дніпровського національного університету ім. Олеся Гончара.

ORCID: <https://orcid.org/0009-0005-3942-3099>

**Suleymanov Yevgeniy** – PhD Student, Department of Software Engineering and Information Technologies, Oles Honchar Dnipro National University.

ORCID: <https://orcid.org/0009-0005-3942-3099>