

В. В. КУЗЬ, А. В. ШАТИРКО

АВТОМАТИЧНА ІДЕНТИФІКАЦІЯ МУЗИЧНИХ ІНСТРУМЕНТІВ

У цій статті досліджується застосування перетворення Фур'є для автоматичного розпізнавання музичних інструментів в аудіозаписах. Зі зростанням складності музичних композицій та потребою в ефективній класифікації аудіо дослідження зосереджується на вилученні детальних спектральних характеристик із звукових сигналів за допомогою швидкого перетворення Фур'є (FFT). Ці характеристики включають спектральний центроїд, ширину смуги пропускання, спад, швидкість перетину нуля та кепстральні коефіцієнти Mel-Frequency (MFCC), які представляють частотні характеристики різних інструментів. Вилучені характеристики обробляються та використовуються для навчання моделей машинного навчання. Зокрема, у статті оцінюється продуктивність двох алгоритмів класифікації: методу апроксимації найближчого сусіда (ANN) та методу опорних векторів (SVM). Моделі навчаються на наборі даних коротких записів на одному інструменті та тестуються на зразках зі змішаних інструментів для оцінки можливостей узагальнення. Експериментальні результати показують, що обидві моделі можуть ефективно класифікувати інструменти з високою точністю – понад 96 % у контрольованих середовищах. Однак точність знижується у складних поліфонічних записах через перекриття частот. У дослідженні також підкреслюється роль таких бібліотек як Librosa, Numpy та Scikit-learn для попередньої обробки та навчання моделей. Результати дослідження показують, що хоча запропонований підхід не ідеально підходить для визначення інструментів в оркестрах, він є дуже ефективним у класифікації сольних інструментів і може бути поширений на такі завдання, як розпізнавання жанрів. Майбутні дослідження можуть включати методи глибинного навчання та розділення джерел звуку для покращення продуктивності в поліфонічних умовах.

Ключові слова: перетворення Фур'є, спектральні характеристики, кепстральні коефіцієнти Mel-Frequency, аналіз сигналів, обробка аудіо, машинне навчання, метод опорних векторів, метод найближчого сусіда.

V. V. KUZ, A. V. SHATYRKO

AUTOMATIC IDENTIFICATION OF MUSICAL INSTRUMENTS

This paper explores the application of the Fourier Transform for automatic musical instrument recognition in audio recordings. With the increasing complexity of musical compositions and the need for efficient audio classification, the study focuses on extracting detailed spectral features from sound signals using the Fast Fourier Transform (FFT). These features include spectral centroid, bandwidth, roll-off, zero-crossing rate, and Mel-Frequency Cepstral Coefficients (MFCCs), which represent the frequency-based characteristics of different instruments. The extracted features are processed and used to train machine learning models. Specifically, the paper evaluates the performance of two classification algorithms: Approximate Nearest Neighbor (ANN) and Support Vector Machine (SVM). The models are trained on a dataset of short mono-instrument recordings and tested on mixed-instrument samples to assess generalization capabilities. The experimental results demonstrate that both models can effectively classify instruments with high accuracy – over 96 % in controlled environments. However, the accuracy decreases in complex polyphonic recordings due to overlapping frequencies. The study also highlights the role of libraries such as Librosa, Numpy, and Scikit-learn for preprocessing and model training. The findings suggest that while the proposed approach is not ideal for overlapping instruments in orchestras, it is highly effective in solo instrument classification and can be extended to tasks like genre recognition. Future research could include deep learning techniques and sound source separation to improve performance in polyphonic settings.

Key words: Fourier transform, spectral features, Mel-Frequency Cepstral Coefficients, signal analysis, audio processing, machine learning, Support Vector Machine, Approximate Nearest Neighbor.

Вступ. Автоматична ідентифікація музичних інструментів в аудіозаписах є важливим завданням у цифровій обробці сигналів. Вона має застосування в класифікації музичних жанрів, пошуку музичної інформації та автоматичній транскрипції. Це дослідження зосереджено на використанні швидкого перетворення Фур'є (FFT) [1] для вилучення спектральних ознак та застосування методів машинного навчання для класифікації інструментів на основі їхніх аудіохарактеристик.

Ми прагнемо дослідити методи обробки та аналізу сигналів, необхідні для автоматичної ідентифікації музичних інструментів. Враховуючи певну мелодію, необхідно реалізувати програму, яка класифікуватиме музичні інструменти в ній.

Аналіз основних відомих теоретичних результатів.

Перетворення Фур'є в аналізі звукових сигналів. Перетворення Фур'є – це фундаментальний інструмент обробки сигналів, який дозволяє проводити перетворення цифрових сигналів з часової області в частотну область. Дискретне перетворення Фур'є (DFT) математично представлено як:

$$X(k) = \sum_{n=0}^{N-1} x(nT) e^{-2\pi i n k / N} = \sum_{n=0}^{N-1} x(nT) W^{-nk}, \quad k = 0, \dots, N-1, \quad (1)$$

де $X(k)$ – представляє спектральні коефіцієнти, $x(n)$ – дискретний сигнал, а N – кількість точок перетворення. FFT – це оптимізована версія DFT, що зменшує обчислювальну складність та робить обробку в реальному часі можливою.

Спектральні характеристики для класифікації інструментів. Спектральні (частотні) характеристики отримують шляхом перетворення часового сигналу в частотну область за допомогою перетворення Фур'є [2]. Це перетворення дозволяє розкласти сигнал на його складові частини за різними частотами.

Спектральні характеристики включають: основну частоту; силу сигналу на кожній частоті; середню частоту сигналу; спектральний центроїд, потік, щільність та затухання.

Спектральний центроїд. Це величина, яка вказує, на якій частоті зосереджена енергія спектра, по суті показуючи, де розташований центр мас звуку:

$$f_c = \frac{\sum_k f(k) S(k)}{\sum_k S(k)}, \quad (2)$$

де $S(k)$ – спектральна величина елемента k , а $f(k)$ – частота елемента k .

Спектральна смуга пропускання. Спектральна смуга пропускання визначається як ширина смуги на половині точки максимуму (або повна ширина на половині максимуму) та представлена двома вертикальними червоними лініями (на наступних рис.) та λ_{SB} на осі довжин хвиль:

$$SB_p = \left(\sum_k S(k) (f(k) - f_c)^p \right)^{\frac{1}{p}}. \quad (3)$$

Ширина смуги пропускання – це різниця між верхньою та нижньою частотами в неперервній смузі частот. Тут $S(k)$ – це спектральна амплітуда на частотному індексі k , $f(k)$ – частота з індексом k , а f_c – спектральний центроїд.

Спектральний контраст. Функція спектрального контрасту (SC) [3] розглядає спектральний пік та частоту спаду кожної підсмуги окремо, таким чином відображаючи відносні спектральні характеристики нижніх смуг. Спектральні піки та спади оцінюються шляхом обчислення середнього значення невеликого околу (визначеного як α) навколо максимуму та мінімуму підсмуги.

Тут k представляє смугу частот, а $x_{k,i}$ – це підсмуга аудіосигналу, упорядкована за спаданням величини магнітуди:

$$Peak_k = \log \left(\frac{1}{\alpha N} \sum_{i=1}^{\alpha N} x_{k,i} \right), \quad Valley_k = \log \left(\frac{1}{\alpha N} \sum_{i=1}^{\alpha N} x_{k,N-i+1} \right), \quad (4)$$

$$SC_k = Peak_k - Valley_k. \quad (5)$$

Спектральне спадання. Це міра форми сигналу, що представляє ту частоту, на якій вищі частоти падають до нуля:

$$\sum_k^{R_c} S(k) = 0.85 \sum_k S(k). \quad (6)$$

Щоб отримати його, потрібно розрахувати частку елементів у спектрі потужності, де 85 % потужності зосереджено на нижчих частотах.

Кенстральні коефіцієнти Mel-частоти (MFCC). Кенстральні коефіцієнти Mel-частоти сигналу (MFCC) – це набір ознак, які коротко описують загальну форму спектральної огинаючої. MFCC отримують шляхом взяття віконного сегмента сигналу (STFT сигналу) та відображення спектральної потужності на шкалу Mel за допомогою трикутних вікон, що перекриваються. Потім обчислюються логарифми потужностей на кожній Mel-частоті. Після цього до списку логарифмічних потужностей на Mel-частотах застосовується дискретне косинусне перетворення (DCT). MFCC – це амплітуди результуючого спектру, які лаконічно описують загальну форму спектральної кривої.

Коефіцієнт перетину нуля (ZCR). Коефіцієнт перетину нуля (ZCR) вказує на кількість перетинів сигналом горизонтальної осі. ZCR – низький для гармонійних звуків і високий для зашумлених звуків:

$$ZCR = \frac{1}{T-1} \sum_{t=1}^{T-1} \mathbb{I} \{ S_t S_{t-1} < 0 \}, \quad (7)$$

де S_t – сигнал довжини t , а $\mathbb{I}$ – індикаторна функція, яка дорівнює 1, якщо умова X істинна (інакше вона дорівнює 0).

Спектральний потік. Це міра того, як швидко змінюється потужність спектру сигналу, розрахована шляхом порівняння спектральної потужності одного кадру з потужністю попереднього кадру. Результат спектрального потоку через $H(x)$ в основному використовується для визначення початку гри музичного інструменту, оскільки він містить лише інформацію про збільшення енергії порівняно з попереднім кадром:

$$SF(n) = \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} H(|X(n, k)| - |X(n-1, k)|), \quad H(x) = \frac{x + |x|}{2}. \quad (8)$$

Алгоритм класифікації інструментів. Після отримання всіх необхідних спектральних характеристик для навчання моделі ми стикаємося з останнім, найцікавішим та найскладнішим завданням – використанням алгоритму машинного навчання для навчання моделі на основі набору музичних творів [4]. З них нам потрібно виділи-

ти відповідні характеристики для порівняння з заданим аудіозаписом та класифікувати інструменти, що грають у нашій мелодії.

Однак існує багато алгоритмів машинного навчання, кожен з яких розроблений для широкого кола завдань. Вони мають різні підходи та характеристики, що роблять їх придатними для різних типів задач. Деякі зосереджені на класифікації даних, інші – на прогнозуванні або кластеризації. Деякі можуть обробляти великі набори даних, а інші більше підходять для роботи з обмеженою кількістю наборів даних. Тому важливо визначити, яка модель є оптимальною для нашого завдання з точки зору досягнення високої точності при мінімальному споживанні зусиль системи [5].

Таблиця 1 – Порівняльна таблиця точності моделей машинного навчання

hypotheses set	SVM	Softmax	GaussianNB	KNN	DT	RF
Timber	91.0	88.0	77.5	84.5	70.5	88.0
Pitch/harmony	63.5	36.5	42	55.0	44.5	55
Rhythm	15.5	14.5	14.0	8.5	6.5	6.5
Timber + Pitch/harmony	90.5	88.0	30	71.0	63.5	89.0
Timber + Rhythm	92.5	88.0	73.0	85.5	61.5	88.5
Pitch/harmony + Rhythm	64	40.5	30.0	56.0	20.0	45.5
Timber + Rhythm + Pitch/harmony	91.5	87.0	77.5	73.0	62.5	90.5

В табл. 1 наведено порівняння точності різних найбільш уживаних моделей, навчених на наборі даних, що складається з 1200 навчальних кліпів, кожен тривалістю 4 секунди [4]. Ми бачимо, що найточнішим методом є SVM, з точністю понад 90 %. Інші моделі також продемонстрували хорошу точність. Однак тривалість аудіозаписів була відносно короткою, і зі збільшенням тривалості точність може спадати.

Метод апроксимації найближчого сусіда (ANN). Цей алгоритм шукає точки, відстань яких не перевищує більше ніж коефіцієнт C від точки запиту до її найближчих сусідів. Перевага цього підходу полягає в тому, що в багатьох випадках приблизний найближчий сусід майже такий же хороший, як і точне рішення. Якщо міра відстані точно відображає сприйняття користувачем якості, невеликі відмінності у відстані не мають суттєвого значення.

Метод опорних векторів (SVM). Метод навчання з учителем, який визначає межі прийняття рішень. Точки даних, найближчі до межі прийняття рішення, називаються *опорними векторами*. Сума відстаней між опорними векторами та межею прийняття рішення називається запасом ($|w|$). SVM прагне максимізувати запас, щоб знайти найоптимальнішу межу класифікації:

$$obj(f) = \max \frac{2}{\|w\|_2} \rightarrow \min \frac{1}{2} \|w\|_2^2, \text{ sub: } y_i (w^T x_i + b) \geq 1. \quad (9)$$

Постановка задачі класифікації музичних інструментів. Робочий процес обробки звуку включає вилучення акустичних характеристик, що стосуються заданого завдання, а потім схеми прийняття рішень, що включають виявлення, класифікацію та інтеграцію знань.

Обчислення перетворення Фур'є допомагає перетворити сигнал у частотну область.

Створення спектрограми візуалізує інтенсивність звуку з плином часу та частоти. Спектрограма представляє амплітуду сигналу або «гучність» на різних частотах з плином часу та зазвичай відображається у вигляді теплової карти.

Щоб реалізувати автоматичне розпізнавання інструментів в аудіозаписі, нам потрібно вилучити основні звукові характеристики для їх обробки нейронною мережею. Модель буде навчатися на основі певних характеристик за допомогою *бібліотек мови Python*. Для цього завдання ми використовуватимемо такі бібліотеки: *Librosa*, *Pandas*, *Numpy*, *Scikit-learn*, *Keras*, *Matplotlib*. Навчання моделі та аналіз даних будуть проводитися в *Google Colab* або *Jupyter Notebook*, які забезпечують інтерактивне середовище для покрокового виконання.

Ідея класифікації. Ми беремо навчальний набір даних – короткі аудіозаписи, кожен з яких містить звук лише одного інструменту. Для кожного аудіозапису генеруємо спектрограму та витягуємо всі необхідні спектральні характеристики. Використовуючи ці характеристики, навчаємо модель.

Крім того, ми вибираємо набір аудіозаписів різної тривалості для тестування, які можуть містити мелодії, що граються кількома інструментами. Далі застосовуємо нашу навчену модель до цього тестового набору та оцінюємо її точність.

Обробка аудіо. Усі необхідні інструменти Python, що використовуються в цьому дослідженні, детально описані в джерелі [6]. Спочатку нам потрібно завантажити аудіофайл з використанням бібліотеки *Librosa*:

```
import librosa
audio_data = './audio.wav'
x, sr = librosa.load(audio_data)
print(type(x), type(sr))
#<class 'numpy.ndarray'> <class 'int'>
print(x.shape, sr)
#(94316,) 22050
```

Далі, використовуючи `librosa.display.waveplot`, побудуємо діаграму форми хвилі аудіомасиву (рис. 1).




Рис. 1 – Діаграма форми хвилі аудіомасиву.

Для візуалізації спектрограми (рис. 2) аудіосигналу ми використовуємо `librosa.display.specshow`:

```
X = librosa.stft(x)
Xdb = librosa.amplitude_to_db(abs(X))
plt.figure(figsize=(14, 5))
librosa.display.specshow(Xdb, sr=sr, x_axis='time', y_axis='hz')
plt.colorbar()
```




Рис. 2 – Спектрограма аудіо сигналу.

Вилучення спектральних ознак. Після отримання спектрограми наступним кроком є вилучення всіх відповідних спектральних ознак, які є важливими для подальшого аналізу та класифікації [7].

```
import sklearn
spectral_centroids = librosa.feature.spectral_centroid(x, sr=sr)[0]
spectral_centroids.shape(775,)
plt.figure(figsize=(12, 4))
frames = range(len(spectral_centroids))
t = librosa.frames_to_time(frames)

# Normalization of the spectral centroid for visualization
def normalize(x, axis=0):
    return sklearn.preprocessing.minmax_scale(x, axis=axis)

# Plotting the spectral centroid along with the waveform
librosa.display.waveplot(x, sr=sr, alpha=0.4)
plt.plot(t, normalize(spectral_centroids), color='b')
```




Рис. 3 – Візуалізація спектрального центроїда та звукової хвилі.

Подібний підхід з використанням бібліотеки Librosa дозволяє нам витягти всі інші раніше означені необхідні спектральні характеристики (рис. 4 – рис. 6).




Рис. 4 – Діаграма спадання частоти.




Рис. 5 – Графік частоти перетину нуля.




Рис. 6 – Кепстральні коефіцієнти Mel-частоти (MFCC).

Таким чином, ми витягуємо спектральні ознаки з кожного аудіозапису в наборі даних, включаючи спектра-

льний центроїд, MFCC, частоту перетину нуля, спектральний спад та спектральне згасання. Після отримання цих ознак ми конвертуємо дані у спектрограми у форматі PNG та зберігаємо всі витягнуті ознаки у файлі CSV, розділяючи дані на навчальні та тестові набори.

Після підготовки ознак наступним кроком є побудова наших моделей.

Побудова моделей. Модель апроксимації найближчого сусіда (ANN):

```
model = Sequential()
model.add(layers.Dense(256, activation='relu', input_shape=(X_train.shape[1],)))
model.add(layers.Dense(128, activation='relu'))
model.add(layers.Dense(64, activation='relu'))
model.add(layers.Dense(10, activation='softmax'))
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

classifier = model.fit(X_train,
                      y_train,
                      epochs=100,
                      batch_size=128)
```

Навчання проводилося протягом 100 епох з використанням не дуже потужної обчислювальної системи. Кожен навчальний аудіозапис містить звук лише одного інструменту: саксофон, труба, скрипка, віолончель, флейта або духовий інструмент (гобой).

```
# SVM
#model_svm = LinearSVC(random_state=0, tol=1e-5, max_iter=5000)
svclassifier = SVC(kernel='rbf', C = 10.0, gamma=0.1)

svclassifier.fit(train_set, train_classes);

joblib.dump(svclassifier, 'trainedSVM.joblib')

predicted_labels = svclassifier.predict(test_set)
```




Рис. 7 – Матриця невідповідностей класифікації музичних інструментів, отримана за допомогою штучних нейронних мереж.

Після цього ми можемо перевірити точність отриманої нами класифікації, переглянувши матрицю невідповідностей (рис. 7). Переглянувши CSV-файл з результатами, ми бачимо, що точність становить 96,67 %.

Аналогічний числовий експеримент на цих же *даних* проведено із застосуванням методу опорних векторів (SVM). Результати його роботи продемонстровані матрицею невідповідностей класифікації, яка співпала з показаною на рис. 7. Точність застосування цієї моделі також близька до ANN й склала 96 %.

Отримані результати. Процес впровадження та навчання моделей штучної нейронної мережі (ANN) та методу опорних векторів (SVM) з вилученими спектральними ознаками був вирішальним кроком в оцінці потенціалу машинного навчання для класифікації музичних інструментів. Після оцінювання обидві моделі продемонстрували високу точність у контрольованих умовах, де аудіозаписи мали мінімальне перекриття звуків від кількох інструментів та мали відносно коротку тривалість. Цей висновок підкреслює ефективність підходу у випадку, коли дані добре відповідають можливостям моделі.

У контрольованих умовах спектральні ознаки, вилучені з аудіо, такі як мел-частоти (MFCC), спектральний центроїд та спектральний потік, виявилися надійними індикаторами для виявлення різних музичних інструментів. Процес навчання був ефективним, і моделі ANN та SVM показали багатообіцяючі результати, точно класифікуючи записи у випадку одного інструменту.

Однак, при переході від контрольованих середовищ до більш складних, реальних оркестрових записів, де кілька інструментів часто перекриваються, моделі зіткнулися зі значними труднощами. Спектральні ознаки, хоча й залишалися інформативними, були недостатніми для розрізнення інструментів, коли їхні звуки зливалися в межах однакових частотних діапазонів. Це обмеження підкреслює складність обробки поліфонічного аудіо, де одночасно присутні кілька джерел звуку. Хоча обидві моделі все ще досить добре працювали за цих умов, їхня точність та надійність помітно постраждали.

Незважаючи на ці ускладнення, підхід залишається цінним для завдань класифікації аудіо, особливо в простіших випадках, таких як класифікація за жанрами або ідентифікація сольних інструментів. У цих застосуваннях спектральні характеристики ефективно фіксують різні звуки, і моделі можна навчити класифікувати їх з високою точністю. Простота методу в поєднанні з його ефективністю в контрольованих умовах робить його доступним інструментом для різних застосувань аналізу аудіо.

Перспективи подальших досліджень. На завершення, застосування спектрального аналізу в поєднанні з алгоритмами машинного навчання, такими як ANN та SVM, забезпечує міцну основу для завдань класифікації, пов'язаних з музикою. Поточний підхід демонструє великі перспективи для контрольованих налаштувань, але потребує подальшого вдосконалення для ефективної обробки складних поліфонічних та аудіосценаріїв з перекриттям звуків різноманітних інструментів. Подальша робота повинна бути зосереджена на покращенні здатності моделей одночасно обробляти кілька інструментів, потенційно включаючи передові методи, такі як розділення джерел або методи глибинного навчання, спеціально розроблені для аналізу поліфонічного звуку.

Список літератури

1. *Заболотний С. В.* Цифрове оброблення сигналів : Посібник для студентів напряму підготовки 6.050901 "Радіотехніка" усіх форм навчання. – Черкаси : ЧДТУ, 2010. – 119 с.
2. *Digital Signal Processing A Practical Guide for Engineers and Scientists by Steven W. Smith.* – Library of Congress Cataloging-in-Publication Data.
3. *Jiang Dan-Ning, Lu Lie, Zhang Hong-Jiang, Tao Jian-Hua, Cai Lian-Hong.* Music type classification by spectral contrast feature In Proceedings // IEEE International Conference on Multimedia and Expo. – 2002. – P. 113 – 116.
4. *Tzanetakis G., Cook P.* Musical genre classification of audio signals // In IEEE Transactions on Speech and Audio Processing. – 2002. – P. 293 – 302.
5. *Ivanenko A., Shatyrko A.* Application for detecting musical instruments in an orchestra // MSTIoE 2024-11. 11-та Східно-Європейська конференція «Математичні та програмні технології Internet of Everything» (11 – 12.04.2024, Київ). – Київ, 2024. – С. 48 – 49.
6. *José Unpingco.* Python for Signal Processing. – San Diego, CA, USA, Springer Cham Heidelberg New York Dordrecht London. DOI 10.1007/978-3-319-01342-8.
7. *Lerch Alexander.* An Introduction to Audio Content Analysis: Applications in Signal Processing and Music Informatics // IEEE Press/Wiley. – 2012. DOI 10.1002/9781118393501.

References (transliterated)

1. *Zabolotniy S. V.* Tsyfrove obroblyennya sygnaliv : posibnyk dlya studentiv napryamu pidgotovky 6.050901 "Radiotekhnika" usikh form navchannya [Digital signal processing: A manual for students of the direction of training 6.050901 "Radio engineering" of all forms of study]. Cherkasy, ChDTU, 2010. 119 p.

2. Digital Signal Processing A Practical Guide for Engineers and Scientists by Steven W. Smith. Library of Congress Cataloging-in-Publication Data.
3. Jiang Dan-Ning, Lu Lie, Zhang Hong-Jiang, Tao Jian-Hua, Cai Lian-Hong. Music type classification by spectral contrast feature In Proceedings. *IEEE International Conference on Multimedia and Expo*. 2002, pp. 113–116.
4. Tzanetakis G., Cook P. Musical genre classification of audio signals. In *IEEE Transactions on Speech and Audio Processing*. 2002, pp. 293–302.
5. Ivanenko A., Shatyрко A. Application for detecting musical instruments in an orchestra. *MSTIoE 2024-11. 11-та Skhidno-Evropeys'ka konferentsiya "Matematychni ta programni tekhnologiyi Internet of Everything" (11 – 12.04.2024, Kyiv)* [MSTIoE 2024-11. 11-та Східно-Европейська конференція «Математичні та програмні технології Internet of Everything» (11 – 12.04.2024, Kyiv)]. Kyiv, 2024, pp. 48–49.
6. José Unpingco. *Python for Signal Processing*. San Diego, CA, USA, Springer Cham Heidelberg New York Dordrecht London. DOI 10.1007/978-3-319-01342-8.
7. Lerch Alexander. An Introduction to Audio Content Analysis: Applications in Signal Processing and Music Informatics. *IEEE Press/Wiley*. 2012. DOI 10.1002/9781118393501.

Надійшла (received) 05.05.2025

Відомості про авторів / Information about authors

Кузь Володимир Вячеславович – магістр кафедри моделювання складних систем факультету комп'ютерних наук та кібернетики, Київський національний університет імені Тараса Шевченка, м. Київ; тел.: (044) 521-32-74; ORCID: <https://orcid.org/0009-0006-0657-8091>; e-mail: vovany364n@gmail.com.

Kuz Volodymyr Vyacheslavovych – Master-student at the Department of Complex Systems Modeling Faculty of Computer Science and Cybernetics, Taras Shevchenko National University of Kyiv, Kyiv; tel.: (044) 521-32-74; ORCID: <https://orcid.org/0009-0006-0657-8091>; e-mail: vovany364n@gmail.com.

Шатирко Андрій Володимирович – доктор фізико-математичних наук, професор, доцент кафедри моделювання складних систем факультету комп'ютерних наук та кібернетики, Київський національний університет імені Тараса Шевченка, м. Київ; тел.: (044) 521-32-74; ORCID: <https://orcid.org/0000-0002-5648-2999>; e-mail: shatyрко.a@knu.ua.

Shatyрко Andriy Volodymyrovych – Doctor of Sciences in Physical and Mathematics, Professor, Associate Professor at the Department of Complex Systems Modeling Faculty of Computer Science and Cybernetics, Taras Shevchenko National University of Kyiv, Kyiv; tel.: (044) 521-32-74; ORCID: <https://orcid.org/0000-0002-5648-2999>; e-mail: shatyрко.a@knu.ua.