

УДК 519.677

С.А. ТАЯНОВ

Національний університет “Львівська політехніка”

ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ РІЗНИХ МЕТОДІВ КЛАСТЕРИЗАЦІЇ ТА КЛАСИФІКАЦІЇ КЛАСТЕРІВ ДЛЯ СТИСКАННЯ МОНОХРОМНИХ ЗОБРАЖЕНЬ ШТУЧНОГО ЗОРУ РОБОТА НА ОСНОВІ КОМПОНЕНТНОГО АНАЛІЗУ

Ї Таянов С.А., 2010

Досліджено ефективність запропонованих методів кластеризації для стискання монохромних зображень штучного зору робота на основі компонентного аналізу, а також визначено ефективність класифікації кластерів для складання матриці перетворень компонентного аналізу.

Efficiency of proposed clustering methods under compression of monochrome images on the base of principal component analysis is investigated in this article and efficiency of cluster classification for completion of transformation matrix of principal component analysis is defined as well.

Вступ. Сьогодні існує багато алгоритмів стискання зображень, багато з яких використовують різні методи кластеризації, тобто розбиття цілого зображення на окремі частини (кластери) та подальшого стискання кожної з тих частин. Це пов'язано з тим, що застосування різних методик стискання зображень безпосередньо для всієї матриці зображення вимагає дуже великої кількості перетворень, і саме розбиттям зображення на окремі частини можна зменшити кількість математичних операцій. Дуже перспективним є застосування компонентного аналізу (Principal Component Analysis PCA) для стискання монохромних зображень, оскільки він дає мінімальну похибку відновлення даних серед існуючих алгоритмів стискання [1], тобто є дуже ефективним.

Аналіз останніх досліджень. При стисканні монохромних зображень за допомогою PCA просторова матриця коефіцієнтів зображення зазвичай перетворюється на одновимірний вектор, який представляється як один відлік у векторному просторі масиву зображень. Це представлення поширене для стискання та розпізнавання зображень, тому що є дуже зручним та має багато переваг. Однак за таким підходом губиться просторова структура зображення. Також виникає інша проблема, яка була зазначена вище та пов'язана з великим розміром матриці перетворень, що призводить до зростання кількості обчислень та вимагає більше пам'яті в процесі стискання та відновлення зображень.

Отже, доцільно застосовувати різні методи кластеризації зображень, які дали б змогу зменшити кількість коефіцієнтів матриці перетворення та разом з тим зберегти просторову структуру зображення. Серед найпоширеніших алгоритмів відомий алгоритм стискання зображень JPEG [2], який добре себе зарекомендував та в якому все зображення розбивається на окремі кластери розміром 8×8 та над кожним кластером здійснюється двовимірне косинусне перетворення. Актуальним є дослідження різних методів кластеризації зображень з різними розмірами кластерів для подальшого стискання адаптивними алгоритмами PCA.

При складанні матриці перетворень (матриці власних векторів PCA) знаходять коваріаційну матрицю на основі масиву зображень або на основі всіх кластерів одного зображення. Але при цьому окремі кластери за структурою є різні, тобто, наприклад, існують кластери, які містять тільки

низькочастотні коефіцієнти, та такі, що містять і високочастотні. Тому складання матриці власних векторів на основі кластерів з різною структурою не є ефективним. У цьому випадку доцільно класифікувати кластери, подібні об'єднати в окремі групи та для них знайти коваріаційну матрицю та відповідно матрицю власних векторів PCA. Застосування окремої матриці власних векторів PCA дасть можливість досягти більших коефіцієнтів стискання.

Постановка задачі. Досліджено ефективність різних методів кластеризації монохромних зображень для різного типу зображень разом з подальшим стисканням на основі адаптивного PCA. Також досліджено ефективність стискання зображень методом адаптивного PCA за допомогою класифікації кластерів та визначення матриці власних векторів для кожної групи кластерів.

Методики кластеризації зображень. На рис. 1 показано різні варіанти кластеризації зображень, які застосовувалися для дослідження ефективності стискання зображень з допомогою адаптивного компонентного аналізу. На рис. 1, а показано принцип кластеризації зображення $n \times n$ (на прикладі 8×8), коли зображення розбивається на прямокутні блоки $n \times n$, і кожний блок являє собою окремий кластер зображення. Вектор значень кластера являє собою набір точок прямокутного блоку, які нумеруються зліва направо та згори донизу, як показано на рис 1а. Для кластера 8×8 довжина i -го вектора значень S_i буде 64 (рис. 1а). Рис. 1, б ілюструє методику кластеризації, коли передбачається розбиття зображення на кластери $n \times n \times p$ (на прикладі $8 \times 8 \times 8$). У цьому випадку зображення також розбивається на прямокутні блоки розміром $n \times n$, але кластером вважається p підряд розташованих блоків по вертикалі або горизонталі. Тоді розмір вектора значень i -го кластера S_i буде $n \times n \times p$ і на прикладі (рис. 1,б) буде $8 \times 8 \times 8 = 512$. Нумеруються значення кожного кластера в прямокутних блоках, так само як і для варіанта на рис. 1, а та продовжується для наступного блоку, тобто якщо від 1 до n^2 нумеруються значення для першого блоку кластера, то для другого буде від $n^2 + 1$ до $2n^2$ і для останнього буде $(p-1)n^2 + 1$ до pn^2 (на рис. 1, б перший блок i -го кластера матиме значення S_{i1} до S_{i64} , другий $S_{i65} - S_{i128}$ та останній $S_{i449} - S_{i512}$).

На рис. 1, в показано варіант кластеризації $n \times n \times p \times p$, де зображення, так само, як і в попередніх випадках, розбивається на прямокутники $n \times n$, і кожний кластер являє собою набір прямокутників. Але в цьому випадку беруться прямокутники, розміщені не тільки строго по горизонталі чи вертикалі зображення один відносно одного, а береться p прямокутників по горизонталі та p по вертикалі. Нумеруються прямокутні блоки зліва направо та згори донизу і окремі точки в них так само. У цьому випадку отримуємо вектор значень кластера довжиною $n^2 p^2$. На рис. 1, в показано варіант кластеризації зображення з розміром кластера $8 \times 8 \times 2 \times 2$ з довжиною вектора значень $8 \times 8 \times 2 \times 2 = 256$. Перевага цього метода порівняно з попереднім є в тому, що прямокутники в кожному кластері розташовуються симетрично по вертикалі та горизонталі, що зменшує видимі границі між сусідніми кластерами зображення при сильному стисканні з допомогою компонентного аналізу та подальшому відновленню. На рис. 1, г показано запропонована методика кластеризації, суть якої полягає в розбитті зображення на окремі частини по вертикалі та горизонталі зображення. Після того кожна з частин розбивається на прямокутні блоки розміром $n \times n$, як і в методі, проілюстрованому на рис. 1а. Прямокутні блоки нумеруються зліва направо та згори донизу. В цьому випадку i -м кластером вважається набір i -х прямокутних блоків з кожної частини зображення. Рис. 1, г ілюструє розбиття зображення на чотири частини, отже, i -й кластер складається з 4-х прямокутних блоків розмір яких для наведеного прикладу

становить 8×8 – тобто отримаємо кластер, кількість значень в якому буде $8 \times 8 \times 4 = 256$. Оскільки ми беремо окремі прямокутні блоки з різних частин зображення, то в цьому випадку ми отримуємо кластер, усереднений по всьому зображенню. При стисканні великих неоднорідних зображень за допомогою наведеної методики кластеризації внаслідок подібності кластерів можливий більший стиск при використанні компонентного аналізу, ніж за допомогою інших методів кластеризації розглянутих вище.

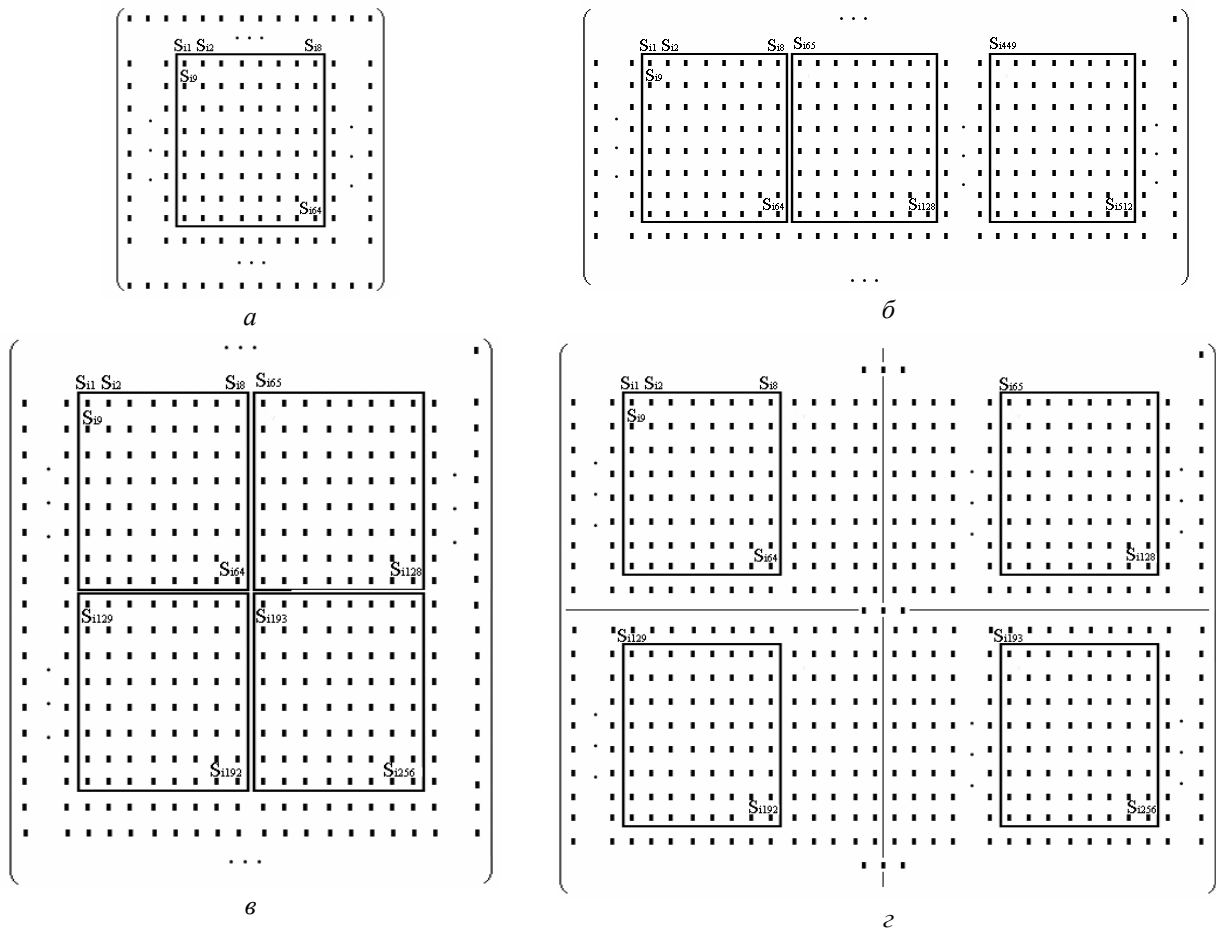


Рис. 1. Різні види кластеризації, що застосовувалися при моделюванні:
 а – кластеризація $n \times n$ (8×8); б – кластеризація $n \times n \times p$; в – кластеризація $n \times n \times p \times p$; г –
 кластеризація методом розбиття зображення на окремі частини

Методика стискання за допомогою адаптивного PCA. Принцип компонентного аналізу зображень полягає в знаходженні коваріаційної матриці Cov на основі окремих зображень або кластерів одного зображення S_i [3]:

$$Cov = \frac{1}{N} \sum_{i=1}^N (S_i - \bar{x})(S_i - \bar{x})^T,$$

де \bar{x} – середнє арифметичне значення елементів матриці зображення A ($\bar{x} = \frac{1}{m \cdot n} \sum_{i=1}^n \sum_{j=1}^m A_{ij}$), N – кількість кластерів або окремих зображень.

Після того з коваріаційної матриці можна отримати матрицю власних векторів [3] Φ , яка буде складатися з N власних векторів, де кожний вектор матиме N елементів. Тоді вектор коефіцієнтів для кожного i -го кластера можна знайти з виразу [4]:

$$C_i = \Phi^{-1} \cdot S_i.$$

Дослідження показали [5], що в кожному векторі найважливіші коефіцієнти за амплітудою йдуть на початку. Принцип стискання полягає в збереженні тільки цих найбільших коефіцієнтів та самої матриці власних векторів. Крім того, можна зберігати тільки ті коефіцієнти матриці власних векторів, що відповідають збереженим коефіцієнтам розкладу.

Запропонований у [5] адаптивний алгоритм стискання полягає в тому, що для різних кластерів вибираємо різну кількість коефіцієнтів розкладу для забезпечення постійного заданого SNR за кожним кластером та обмежуємо максимальну кількість коефіцієнтів розкладу. Після стиску відновити кластери можна за формулою:

$$S'_i = \Phi' \cdot C'_i,$$

де Φ' , C'_i – збережені матриця власних векторів та коефіцієнти розкладу i -го кластера відповідно.

Дослідження ефективності різних методів кластеризації для стискання за допомогою PCA. Зображення, які використовувалися для моделювання ефективності запропонованих методик кластеризації для подальшого стискання з допомогою компонентного аналізу, подано на рис. 2. На рис. 2, а наведено зображення “Lena”, яке має чіткі контури та дуже контрастне (для моделювання використовувалося це зображення з різною роздільною здатністю 256x256 та 512x512). Якщо подивитися на рис. 2, б, то зображення на ньому (“Elaine”) (для моделювання використовується 256x256 та 512x512) має розмитий фон, а на рис. 2, в (зображення “Boat”) (512x512) має багато нечітких фонових деталей – таких, як небо, хмари, море. На рис. 2, г (736x1024) та 2д (800x1120) наведенні варіанти з текстом, причому на рис. 2, г текст має розмитий фон, а зображення на рис. 2, д не має фону і є чіткішим.

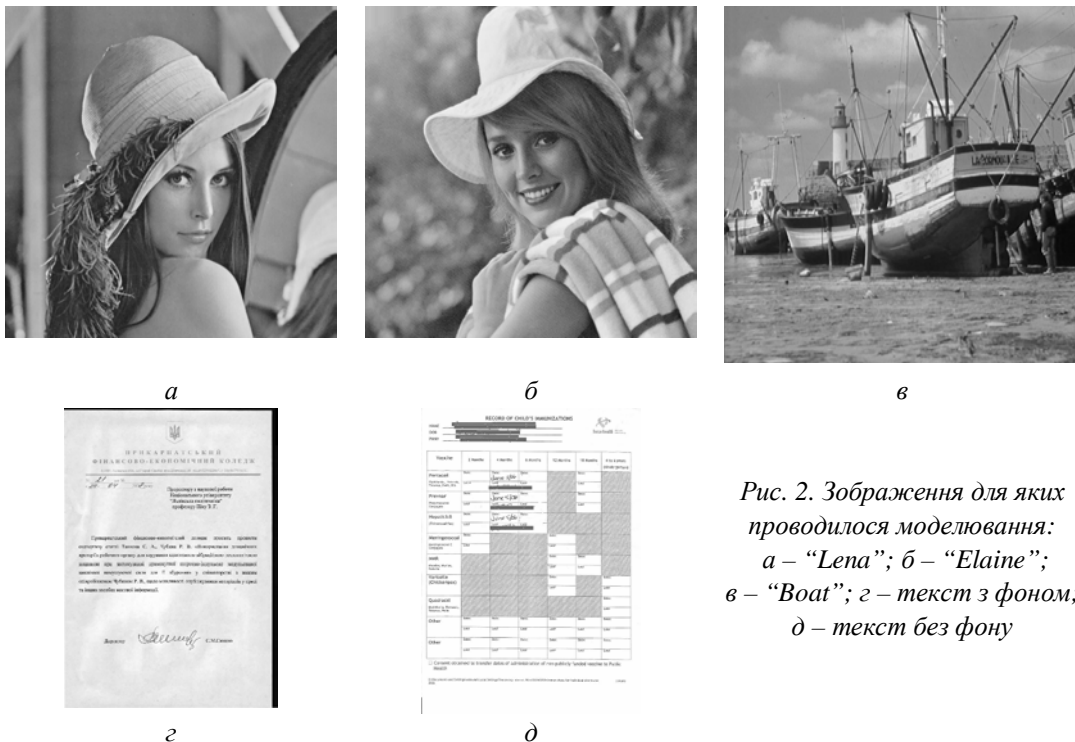


Рис. 2. Зображення для яких проводилося моделювання:
а – “Lena”; б – “Elaine”;
в – “Boat”; г – текст з фоном;
д – текст без фону

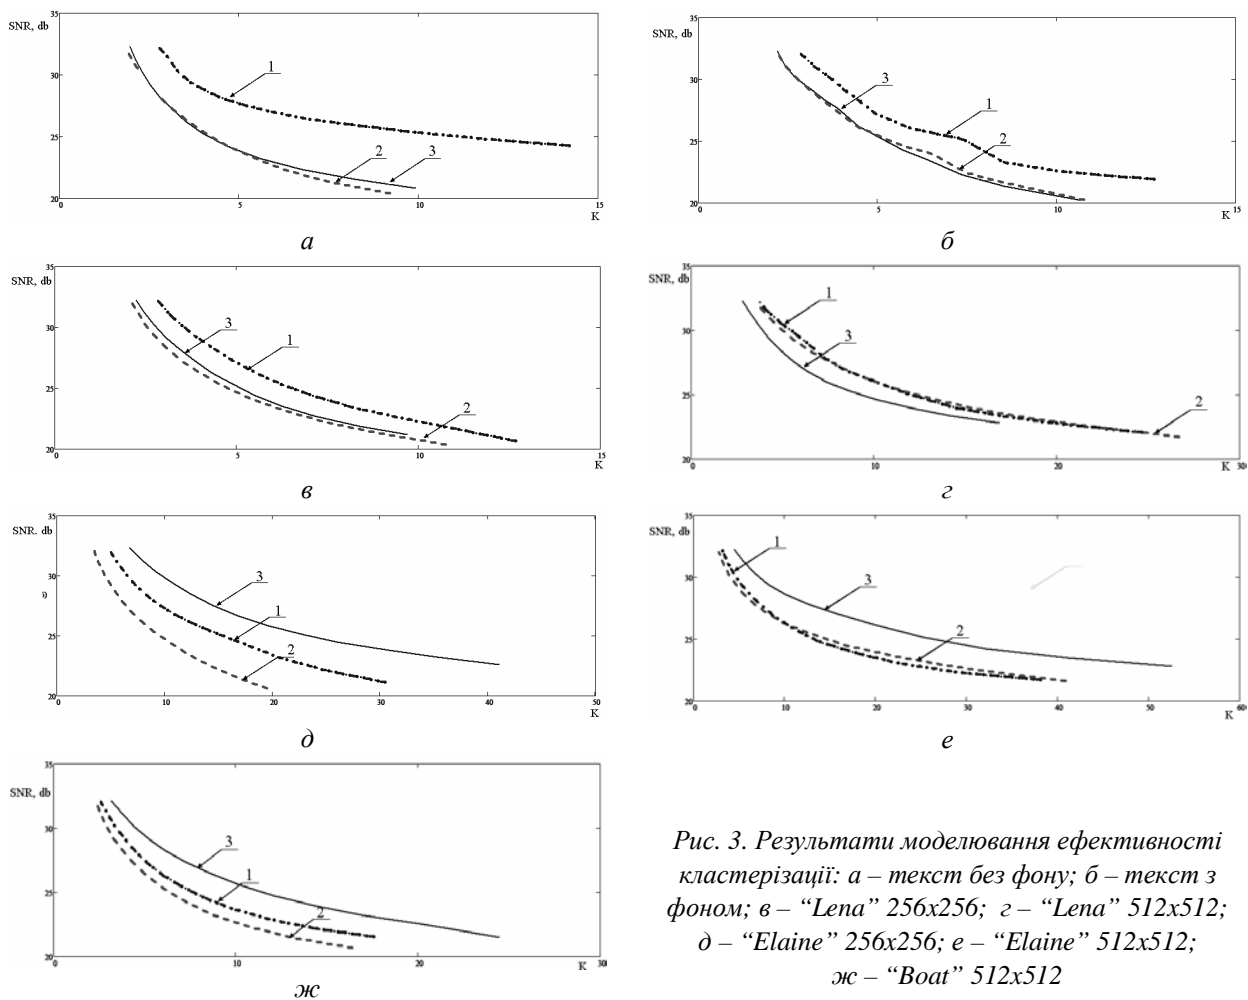


Рис. 3. Результати моделювання ефективності кластеризації: а – текст без фону; б – текст з фоном; в – “Lena” 256x256; г – “Lena” 512x512; д – “Elaine” 256x256; е – “Elaine” 512x512; ж – “Boat” 512x512

Результати моделювання ефективності запропонованих методик наведено на рис. 3. Графіки описують залежність співвідношення сигнал–шум SNR від коефіцієнта K , який являє собою співвідношення кількості значень в кластері до середньої кількості коефіцієнтів перетворення для одного кластера для досягнення заданого SNR . При моделюванні використано розмір кластера 256 для всіх методів кластеризації та зображень. На всіх графіках 1 показано результати моделювання при використанні кластерів, наведених на рис. 1, а та 1, в, де для 1, а розмір кластера $16 \times 16 = 256$, а для 1, в – $8 \times 8 \times 2 = 256$. Як видно зі всіх графіків результати для цих двох методик повністю збігаються. 2 – позначена залежність SNR від K для методики 1, г (тут розмір блока 8×8 , кількість блоків 4 як на рис. 1, г), а 3 – для 1б (розмір кластера $8 \times 8 \times 4 = 256$ елементів).

Застосовуючи різні методики кластеризації для тексту без фону і з фоном (як видно з рис. 3, а та 3, б), найкращих результатів отримано у разі застосування методів кластеризації, наведених на рис. 1, а та 1, в. Причому кращого результату досягають, якщо ці методики застосовують для зображень без фону. Дві інші методики для тексту дають майже однакові результати. При дослідженні контрастного зображення “Lena” меншого розміру отримуємо майже такий самий результат, а при збільшенні розміру зображення (512x512) методика з рис. 1, г дає такий самий результат, як і методики, показані на рис. 1, а та 1, в. При дослідженні методик на зображенні з розмитим фоном “Elaine” (рис. 3, д та 3, е) найкращі результати показала методика, зображена на рис. 1, б, причому на меншому зображенні (рис. 3, д) методика з рис. 1, г показала найгірші результати. Для зображення “Boat” отримані результати, які схожі з результатами для малого зображення “Elaine” (рис. 3, д).

Отже, для високонтрастних зображень малого розміру та тексту найбільш ефективна методика $n \times n$ (рис. 1а) або $n \times n \times p \times p$ (рис. 1, в). Для великих контрастних зображень може бути ефективна методика кластеризації методом розбиття зображення на окремі частини (рис. 1, г). Але для зображень з розмитим фоном типу "Elaine" та зображень з нечітким фоном, наприклад, "Boat", найбільш ефективна методика $n \times n \times p$ (рис. 1, б).

Дослідження ефективності класифікації кластерів. На рис. 4 наведені результати дослідження кількості кластерів зображення N_c від кількості коефіцієнтів компонентного аналізу N_k , яких достатньо для забезпечення заданого SNR для 3-х різних SNR . На рис. 4, а наведено результати дослідження для зображення "Lena" (512x512) та на рис. 4, б – для тексту без фону. На графіках 4, а 1 – це залежність для $SNR=25db$, 2 – для $SNR=28db$ та 3 – для $SNR=32db$. Своєю чергою, на графіку 4, б показано 1 – для $SNR=25db$, та 2 – для $SNR=32db$.

Як видно з рис. 4, а для 25db 4 коефіцієнта перетворення достатньо для більш ніж 300 кластерів з 1024 ($512 \times 512 / 256 = 1024$), тобто таких кластерів 30%. Для $SNR=28db$ 5-ти коефіцієнтів достатньо для 25% кластерів, а для $SNR=32db$ достатньо для більш ніж 10% кластерів. Якщо подивитися на рис. 4, б – то для досягнення 25db потрібно 5 коефіцієнтів для 40% кластерів ($1450 * 100\% / (800 \times 1120 / 256)$). Подібна ситуація і з 32 db.




Рис. 4. Залежність кількості кластерів від кількості коефіцієнтів розкладу:
а – "Lena" 512x512; б – текст без фону




Рис. 5. Результати моделювання ефективності класифікації кластерів:
а – залежність кількості кластерів від кількості коефіцієнтів на один кластер;
б – залежність середньої кількості коефіцієнтів на один кластер від кількості кластерів

Пропонується методика збільшення ефективності стиснення за допомогою компонентного аналізу, суть якої полягає в розбитті всієї кількості кластерів на групи за кількістю коефіцієнтів перетворення PCA, які потрібні для забезпечення заданого SNR . Після того для кожної з груп пропонується знайти власну матрицю власних векторів та зробити PCA на її основі для цієї групи.

На рис. 5 показано результати, яких можна досягти, розбивши всі кластери на групи (класифікувавши їх). Наприклад, на рис. 5, а показано залежність кількості кластерів від кількості коефіцієнтів розкладу для зображення “Lena” (512x512) для 25db, якщо кластери, які мають 4 коефіцієнти, об’єднати в групу, знайти для них власні вектори та розкласти методом PCA. При цьому середня кількість коефіцієнтів, потрібна для забезпечення $SNR=25db$, дорівнює 1.19, як видно з рис. 5, а. Для тексту без фону і для групи кластерів з 5-ма коефіцієнтами для $SNR=25db$ середня кількість коефіцієнтів буде 1, тобто достатньо тільки 1 коефіцієнта з 256 для 40% кластерів.

Проведені дослідження показали, що ефективність вищевказаного запропонованого методу зростає зі збільшенням кластерів в групі. Так, наприклад, якщо взяти з тієї самої групи кластерів менше кластерів, ніж в результаті, показаному на рис. 5, а (там було більш ніж 300 кластерів) і знайти для них матрицю власних векторів і коефіцієнти – то отримуємо залежність середньої кількості коефіцієнтів N_k від кількості кластерів у групі N_c , яка наведена на рис 5, б. Тобто для забезпечення цього ефекту потрібно мінімум 20 кластерів. Насправді числові моделювання підтвердило: чим більше кластерів в групі, тим більший ефект.




Рис. 6. Залежність кількості кластерів від кількості коефіцієнтів на один кластер для об’єднаної групи кластерів

Якщо в групі мало кластерів, то можна об’єднати декілька груп в одну та знаходити для них матрицю власних векторів PCA та на її основі знаходити коефіцієнти перетворення. На рис. 6 показано результати об’єднання в групу кластерів з кількістю коефіцієнтів від 8 до 14. Після перетворення для основної маси кластерів було достатньо 4 коефіцієнтів (рис. 6), а середня кількість коефіцієнтів становила 6.044.

Висновок. Отже досліджено ефективність кластеризації за допомогою запропонованих методик для різного типу зображень та виявлено найоптимальніші методики для стискання контрастних зображень, зображень з нечітким фоном та тексту. Запропоновано та досліджено методику класифікації кластерів для подальшого стискання методом адаптивного компонентного аналізу та доведено за допомогою моделювання її ефективність.

1. Hui Kong, Lei Wang, Eam Khwang Teoh, Xuchun Li, Jian-Gang Wang, Ronda Venkateswarlu. Generalized 2D principal component analysis for face image representation and recognition. *Neural Networks, Volume 18, Issues 5-6, July-August 2005, Pages 585-594.* 2. JPEG: ITU-T Rec. T.81-ISO/IEC. No. 10918-1, “Information Technology – Digital compression and Coding of Continuous-Tone Still Images”, 1993. 3. Таянов С.А. Дослідження компресії на основі компонентного аналізу кластерів зображень штучного зору робота //Автоматизація виробничих процесів у машинобудуванні та приладобудуванні: Український міжвідомчий науково-технічний збірник. – 2009. – Вип. №43. – С. 94–98. 4. Таянов С.А., Таянов В.А. Дослідження ефективності стискання зображень на основі адаптивного кластерного компонентного аналізу // Наукові вісті Галицької академії. – 2009. – Вип. № 2(14). – С. 31–36. 5. Таянов С.А., Таянов В.А. Методика кластеризації зображень для їх компресії на основі компонентного аналізу //Автоматизированные системы управления и приборы автоматики: Український міжвідомчий науково-технічний збірник. – 2008. – Вип. №145. – С.63–68.