

ДОСЛІДЖЕННЯ ТА АНАЛІЗ МЕТОДІВ ЗАБЕЗПЕЧЕННЯ НАДВИСОКОЇ РОЗДІЛЬНОЇ ЗДАТНОСТІ ЗОБРАЖЕНЬ НА ОСНОВІ МАШИННОГО НАВЧАННЯ

© Ізонін І., 2017

Досліджено методи забезпечення надвисокої роздільної здатності зображень на основі машинного навчання. Проаналізовано роботу різних груп цих методів, подано їхні переваги та недоліки. На основі проведених практичних експериментів здійснено порівняльний аналіз (за критерієм PSNR) методів забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення з різних класів. Експериментально встановлено, що найкращі результати отримано при використанні методу на основі конволюційної нейронної мережі. Незважаючи на часо- та ресурсозатратну процедуру навчання за цим методом, його навчальну модель можна використовувати для обробки зображень різних класів.

Ключові слова: зображення, надвисока роздільна здатність, методи на основі навчання, нейронні мережі.

In this article the methods of image superresolution based on machine learning are investigated. The work of different groups of these methods are analyzed. Basic features of this methods are describing. On the basis of practical experiments comparative analysis (by the criterion PSNR) of the superresolution methods in the case of one input image from different classes were conducted. Experimentally found that the best results are obtained in case of using the method based on the convolutional neural network. Despite the requirement on the time and resources which are needed to implement the training procedures of this method, its training model can be used in the processing of images of different classes.

Key words: images, super-resolution, learning-based methods, neural networks.

Вступ

Задача забезпечення надвисокої роздільної здатності (super resolution) – це задача, яка переважно формулюється в оберненій формі і розв’язується методом чи набором методів, призначених для збереження найтонших деталей зображення завдяки обробці одного вхідного зображення чи набору вхідних зображень однієї сцени, внаслідок збільшення кількості пікселів на одиницю площі у вихідному зразку.

Подібні методи для випадку одного вхідного зображення ґрунтуються на реконструкції або навчанні. В інших методах, у випадку набору зображень однієї сцени, використовують додаткову інформативність на основі субпіксельного зсуву на неціле значення піксела у середині набору.

Метою роботи є дослідження та порівняння методів забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення

Дослідження та аналіз методів забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення

Методи забезпечення надвисокої роздільної здатності (РЗ) зображення під час обробки одного зображення можна поділити на дві основні групи (рис. 1): на основі реконструкції та на основі навчання [1].

Метою методів забезпечення надвисокої РЗ зображень на основі технології реконструкції є відновлення деталей зображення внаслідок інтерполяції вхідного зразка низької РЗ із збереженням різкості країв зображення. Різновидів подібних алгоритмів є чимало. Деякі методи [2, 3] призначені для видалення або зменшення прояву артефактів згладжування. Для цього в них використовують так звані “первинні ескізи” – природні, основні елементи розпізнавання [3] як апіорну інформацію у роботі алгоритму. Першим кроком згідно з процедурою є збільшення РЗ (бікубічна інтерполяція) вхідного зразка низької РЗ до цільового значення коефіцієнта збільшення. Потім отримане зображення, яке вважають низькочастотною компонентою результуючого зображення, розбивають на дві групи: примітиви та непримітивні частини. Ключовим моментом тут є те, що подальші кроки алгоритму виконують лише для примітивів зображення. Кожен примітив в отриманій групі визначають як частину підкласу (край, кут, тощо) на різних масштабах, позиціях у просторі тощо. Навчальні дані кожного підкласу (пари низькочастотного та високочастотного примітивів) формують на основі множини природних цифрових зображень. Наступним кроком процедури є вибір високочастотних примітивів-кандидатів з початкової вибірки на основі низькочастотних примітивів вхідного зразка, отриманого на першому кроці алгоритму. Потім на основі марковських моделей із отриманих примітивів-кандидатів виводять високочастотну групу примітивів, яку разом із низькочастотним зображенням вважають розв’язком задачі забезпечення надвисокої РЗ. Перевагою цих методів є мала розмірність навчальної вибірки, оскільки, як досліджено у [4], внутрішня розмірність примітивів зображення дуже мала. Проте заміна окремих фреймів зображення високої РЗ на високочастотні примітиви, отримані за алгоритмом, не завжди дає задовільні результати.



Рис. 1. Класифікація методів забезпечення надвисокої роздільної здатності у випадку обробки одного вхідного зображення

Інша група методів [5–7] під час розв’язання задачі забезпечення надвисокої РЗ використовує gradientні профілі. Їх застосування пояснюється високою стійкістю при масштабуванні зображень [7]. Окрім цього, працюючи в області gradientа, можна уникнути ряду артефактів на результуючому зображенні, зокрема ефекту “дзвону”. Ці методи, як і методи попередньої групи, знаходять відповідності між статистиками форми (в цьому випадку – gradientні профілі різкості) зображень низької та високої РЗ на основі навчання. Отриману інформацію використовують для накладання обмежень на основі gradientа у процесі реконструкції.

Однією з найважливіших і складних частин цих методів є пошук правильного gradientного профілю [6]. Для розв’язання цієї задачі насамперед потрібно отримати gradient і контурну мапу

зображення. Останню можна визначити із застосуванням алгоритму виявлення краю на основі градієнтів. Контурні пікселі зазвичай є центральними точками градієнтних профілів. Алгоритми трасування у [7] в деяких ситуаціях можуть бути не точними, оскільки в них враховано лише величину градієнта, а інформація про напрямок ігнорується. Це може зумовити плутанину між контурними і неконтурними пікселями, особливо в регіонах, де напрямки градієнта швидко змінюються [8]. Наслідком цієї ситуації є те, що контур буде знайдено, проте він та початкова точка можуть не належати одному градієнтному профілю. У [7] запропоновано модифікацію алгоритму пошуку градієнтних профілів. Згідно з нею, обчислюючи градієнт, беруть до уваги як його величину, так і напрямок. Окрім цього, процедура не потребує інтерполяції, що зменшує час роботи методу.

У [9] проблему реконструкції зображення формулюють як задачу оптимізації функції енергії, що складається зі згущеності та розрідженості точки регуляризації. Локальні обмеження тут встановлюють для покращення мапи градієнта, тоді як глобальні обмеження розрідженості встановлюють на поле градієнта з метою зменшення шуму на результуючому зображенні. Задачу забезпечення надвисокої РЗ згідно із методом розв'язують за методом поділу змінних та методами штрафу.

Незважаючи на задовільні результати роботи за методами забезпечення надвисокої РЗ на основі реконструкції, спостерігаються й недоліки. Зокрема за великих коефіцієнтів збільшення РЗ контури об'єктів на зображенні стають однорідними, змазаними, що зумовлює неприродний вигляд зображення. Їхня продуктивність залежить від використовуваної апріорної інформації та її сумісності із заданими зображеннями. Окрім цього, ці методи потребують post-обробки.

Методи забезпечення надвисокої РЗ на основі навчання передбачають створення навчальної моделі для визначення відповідностей між зображеннями низької та високої РЗ, які зазвичай встановлюють з бази даних (зображення з об'єктом уваги високої РЗ, переважно задане, а зображення з низькою роздільною здатністю створюють зменшенням частоти дискретизації або проріджуванням).

Процедура забезпечення надвисокої РЗ полягає у застосуванні отриманої “навченої” моделі для реконструкції зображення високої РЗ із вхідного зразка низької роздільної здатності.

За різноманітними методами цього класу відновлюють відсутні деталі на результуючому зображенні з використанням подібності між вхідним зразком низької РЗ і прикладами в навчальній множині [1].

Методи на основі навчання можуть працювати за двома підходами. Перший – попиксельний підхід, коли кожне значення в результуючому зображенні високої РЗ отримують у результаті обробки сусідніх пікселів з використанням статистичного навчання. Така обробка може ґрунтуватися на зваженому середньому сусідніх пікселів. Методи цього підходу характеризуються ефективністю щодо усунення змазів та приглушення шумів на зображенні [10]. Іншим підходом є фреймовий [11]. Він передбачає оцінювання взаємозв'язків між фреймами зображень низької та високої РЗ. Саме її використовують для відновлення найімовірніших фреймів у результуючому зображенні на основі фреймів із вхідного зразка низької РЗ. Ефективність таких процедур великою мірою залежить від якості, а в деяких випадках – розмірності навчальної вибірки. Тому основним завданням методів цієї групи є вирішення проблеми формування ефективних навчальних пар із фреймів зображень низької/високої РЗ.

Методи надвисокої РЗ на основі пірамід особливостей описано у роботах [12–14]. Статистичні моделі цих методів передбачають побудову на основі вхідного зображення трьох пірамід “знизу–догори”: Гаусса, Лапласа та піраміди особливостей (“локальних текстурних мір”) згідно з процедурами, поданими у [13]. Піраміда Гаусса формується згорткою зображення із застосуванням алгоритму проріджування з коефіцієнтом 2 за кожним рівнем і використовується для побудови двох інших пірамід. Нижні рівні піраміди Лапласа розглядають як високочастотні компоненти вихідного зображення. Саме тому результуюче зображення високої РЗ формують додаванням зображень пірамід Гаусса та Лапласа одного рівня. Багаторівневе представлення зображення дає змогу будувати непараметричне навчання за співвідношеннями множини пікселів пірамід особливостей та Лапласа між двома сусідніми рівнями з використанням L_2 – метрики. На основі такої системи для тестового зображення шукають найімовірніше зображення (фрейми) високої РЗ серед відповідних зразків з усіх пірамід. Інколи для розв'язання цієї задачі використовують метод найближчого сусіднього значення. Враховуючи низьку швидкість роботи цих методів, у [13] для пошуку найімовірнішого зразка (фрейму) використовують

деревоподібну структуру. Проте результати їх роботи характеризуються спотворенням деяких регіонів результуючого зображення. Для зменшення прояву цього недоліку у [14] розроблено модифіковану схему роботи методів цього підходу. Її ідея теж ґрунтується на властивостях самоподібності між фреймами зображень, наведених у вигляді пірамід. Проте ці методи використовують лише одну піраміду для побудови навчальної вибірки. У [14] будують піраміду Гаусса і використовують контекстно-обмежену сегментацію зображення i -го рівня для формування навчальної вибірки із фреймів різних контекстних категорій. У [12] для цього застосовують кластеризацію. Таку саму ідею використано і у [13], проте замість піраміди Гаусса тут будують трирівневу піраміду Лапласа. Взаємозв'язки між фреймами низької/високої РЗ для усіх трьох методів встановлюють на основі методу опорних векторів.

Інші методи цієї групи ґрунтуються на аналогічних підходах, проте всі вони мають недоліки. Очевидно, що багаторівневе представлення зображення, ще й у вигляді декількох пірамід супроводжується використанням великого обсягу обчислювальних ресурсів. Окрім цього, процес навчання може бути дуже повільним, а прогнозування очікуваних фреймів – не завжди точним. Також у складних імовірнісних моделях методів цього класу не враховано глобальних обмежень. Це призводить до того, що деякі глобальні властивості об'єкта уваги на зображенні, такі як явні контури, когерентність освітлення, а також симетрія, упускаються.

Інший напрямок методів забезпечення надвисокої роздільної здатності зображень – методи на основі розрідженого представлення (sparse coding) [15, 16]. Вони використовують припущення про те, що кожен фрейм із цільового зображення можна подати (sparse decomposition) лінійною комбінацією декількох елементів навчальної вибірки. Інакше кажучи, кожен фрейм із цільового зображення генерується множенням елементів навчальної вибірки на розріджені вектори коефіцієнтів. За цим припущенням розроблено навчальну вибірку на основі навчання пар зображень для розрідженої реконструкції зображення [15], який надалі названо методом Янга. Подальший розвиток методів цього класу полягав у зменшенні часу роботи подібних процедур та підвищенні якості вихідних зображень. З цією метою розроблено метод [16] (метод Зейде), в якому використовують зменшення розмірності застосуванням методу Аналізу Головних Компонент і K-SVD алгоритму та ортогонального узгодженого переслідування (Orthogonal Matching Pursuit) – для навчання “словника”.

Описаний клас методів значно зменшує кількість навчальних вибірок до невеликих “словників” з більшими властивостями до узагальнення, проте їх оптимізація потребує використання процедури розрідженої декомпозиції (sparse decomposition), що може бути зовсім не тривіальним завданням. Окрім цього, ці методи продукують різкі границі вихідних фреймів зображення високої роздільної здатності, що впливає на загальну якість синтезованого зображення.

Застосування довірчих мереж (belief networks), таких як марковські мережі чи деревоподібні структури, до задач забезпечення надвисокої РЗ описано у [17, 18]. Згідно з процедурою цих методів, пару зображень низької/високої РЗ розбивають на фрейми. Для відповідних фреймів обчислюють дві функції: функцію спостереження (observation function) та функцію переходу (transition function) [18]. Функцію спостереження використовують для оцінювання того, наскільки точно фрейм-кандидат високої РЗ відповідає фрейму низької РЗ, а функція переходу оцінює точність відповідності між фреймом-кандидатом високої РЗ та його сусідом. У навчальній моделі цих методів використано алгоритм поширення довіри (belief propagation algorithm) на марковське випадкове поле. Його метою є продукування найімовірнішого фрейму високої РЗ, зв'язуючи його з кожним відомим фреймом низької РЗ так, щоб сусідні ділянки були сумісними одна з однією. Для навчання та виведення використовують приховану марковську модель для факторизації апостеріорної імовірності. Основним недоліком методів цієї групи є те, що вони показують задовільні результати лише за малих коефіцієнтів збільшення РЗ [17, 18].

Концепція нейромережових методів забезпечення надвисокої РЗ зображення схожа на концепцію методів на основі довірчих мереж. Змінюється лише тип ШНМ, що використовується для навчання.

Першою вагомою роботою в напрямку розв'язання цієї задачі на основі штучних нейронних мереж є [19]. У цій дисертації зроблено спробу розв'язати задачу збільшення РЗ зображень (відбитків пальців) на основі фреймової обробки зображення мережею Хопфілда. Розвиток подальших досліджень щодо застосування цього типу ШНМ ґрунтується на формулюванні задачі забезпечення надвисокої РЗ як задачі

м'якої класифікації [20] фреймів із зображень (наприклад, ґрунтово-рослинного покриву), отриманих дистанційним зондуванням. Основна ідея методів цієї групи – максимізація просторової залежності фреймів ґрунтово-рослинного покриву і підтримка пропорційної інформації про клас цього покриву. Саме м'яка класифікація забезпечує можливість продукування набору пропорційних зображень, кожне з яких містить субпіксельну інформацію на заданому класі. Подібну інформацію можна використовувати як джерело додаткової інформації для підвищення детальності і точності результатів роботи методів забезпечення надвисокої РЗ, наприклад, для панхроматичних зображень [21].

Однак у цих методах [19, 21] використано ізотропну просторову модель, побудовану на припущенні, що просторова залежність класів земельного покриття є гомогенною та спрощеною, якщо вона змінюється з напрямом. Отже, напрями просторової субпіксельної залежності різних класів (у нашому випадку ґрунтово-рослинного покриву) є ізотропними. Це накладає низку обмежень щодо точності прогнозування границі між класами, що може унеможливити збереження форми кордонів краю. У [22] з метою усунення цього недоліку застосовують анізотропну модель. Незважаючи на те, що точність роботи цих методів покращилася, вони можуть бути застосовані лише до конкретних класів зображень (у цьому випадку земельного покриву). У [21] запропоновано універсальний підхід. Окрім того, що він ґрунтується на анізотропній просторовій моделі, він також використовує оператор Собеля для виявлення величини та напрямку градієнта. Напрямок градієнта використовують для визначення напрямку субпіксельної просторової залежності. Величину градієнта використовують для визначення ваг сусідніх пікселів у системі. Метод здатен генерувати точніші карти. Ця перевага стає очевидною, коли коефіцієнт збільшення РЗ – великий, а розмір вікна розбиття більший. Проте за зміни параметрів методу результати його роботи є незадовільними. Відсутність можливості автоматичного визначення параметрів методу не дає змоги його застосувати на практиці.

Приклад застосування багатшарових перцептронів для розв'язання поставленої задачі подано у [23]. Тут задачу забезпечення надвисокої РЗ розв'язують вирішенням проблеми пошуку кращого невідомого пікселя між двома існуючими з допомогою цього типу ШНМ. У [23] використано інший підхід. Запропонована схема полягає в сумісному використанні алгоритму довільної інтерполяції та ШНМ. Згідно з процедурою, ШНМ застосовують для моделювання залишкових помилок між інтерпольованим зображенням і відповідним йому зразком низької РЗ. Обчислювальні ресурси, необхідні для роботи методу, значно менші порівняно з вищеописаними методами, а результати роботи значно кращі як для штучних, так і природних цифрових зображень. Проте, оскільки результати роботи багатшарового перцептрона не повторюються, застосування подібного інструментарію накладає низку обмежень на практичне використання методу.

У [24] описано інший підхід до розв'язання поставленої задачі. Метод з використанням конволюційної нейронної мережі (КНМ), або метод Донга відрізняється від існуючих насамперед тим, що навчання відбувається безпосередньо зіставленням пари зображень низької та високої РЗ. Результати такого навчання відображаються у вигляді глибокої конволюційної ШНМ. На вхід цього методу подається зображення низької РЗ, а на виході синтезується зображення підвищеної РЗ.

Розроблена конволюційна ШНМ має просту структуру – три шари. Кожен з них має своє функціональне призначення. Перший шар виділяє ознаки на вхідному зображенні і представляє кожну ділянку у вигляді одновимірного вектора. Другий шар нелінійно зіставляє ці вектори-ознак з іншою множиною векторів-ознак, які концептуально представляють фрейми зображення високої РЗ. Третій шар рекомбінує ці зіставлення і синтезує вихідне зображення підвищеної РЗ. Метод демонструє хороші результати при розв'язанні задачі збільшення РЗ зображень і характеризується високою швидкістю в режимі застосування [24].

Проте цей метод має й недоліки. Експериментально встановлено, що якість синтезованих цим методом зображень великою мірою залежить від обсягу навчальної вибірки. Оскільки навчання такої ШНМ передбачає використання алгоритму зворотного поширення похибки, а збільшення часу процедури навчання показує кращі результати синтезованих зображень підвищеної РЗ згідно з PSNR, то це зумовлює надзвичайно тривалий, ітераційний процес навчання [24]. Окрім цього, цей алгоритм характеризується ще низкою недоліків (правильний підбір кроку, локальні мінімуми тощо), що накладає деякі обмеження на його використання в прикладних задачах систем технічного зору, що ґрунтуються на засадах штучного інтелекту.

У [25] розроблено метод забезпечення надвисокої роздільної здатності зображень на основі використання нейроподібних структур моделі геометричних перетворень. Особливістю цього методу є неітераційна, швидка процедура навчання, яка відбувається лише на одній парі зображень. Метод передбачає передобробку зображень, навчання і застосування. Попередня обробка полягає у представленні навчальної пари зображень у вигляді таблиці вхід/вихід, де входами є фрейми із зображенням низької роздільної здатності, а виходи – фрейми із зображенням низької роздільної здатності. У [25] виявлено найкращі параметри НПС МГП для розв’язання поставленої задачі.

Очевидно, що методи цієї групи повинні характеризуватися високим ступенем генералізації. Однією з можливостей забезпечення цього може бути збільшення кількості зразків. У деяких випадках [24] це себе виправдовує. Проте використання великої навчальної бази (для окремих методів) не формує кращих результатів, оскільки наявність великої кількості несуттєвих прикладів великою мірою впливає на результати роботи методу [26]. Також збільшення навчальної бази збільшує час обчислень під час пошуку найімовірніших зразків для формування вихідного зображення, що накладає обмеження при застосуванні методу у системах реального часу. Іншим недоліком цих методів є те, що вони не гарантують отримання істинної високої РЗ деталей зображення, якщо вхідний кадр містить текстури, яких не існує в базі даних.

Експериментальне порівняння методів забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення

Для дослідження обрано найвживаніші та перспективні методи забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення: методи Янга, Зейде; методи на основі використання градієнтних профілів, нейроподібної структури моделі геометричних перетворень та конволюційної нейронної мережі; класичний метод – бікубічна інтерполяція. Параметри роботи методу Янга наведено у [15], Зейде – у [16], градієнтних профілів – у [6]. Навчальну вибірку методу на основі конволюційної нейронної мережі, за якою синтезували зображення високої роздільної здатності, наведено у [24]. Навчання методу забезпечення надвисокої роздільної здатності зображень на основі НПС МГП відбувалося на парі зображень з рис. 3 (зображення низької роздільної здатності – № 1, зображення високої роздільної здатності у роботі не наведено). Параметри роботи НПС МГП наведено у [25, 26].



Рис. 2. Зразки зображень тестової вибірки (168×168 пікселів)

Для експериментального порівняння досліджуваних методів обрано 6 різних зображень, які подано на рис. 2. Зображення в градаціях сірого, двобайтні, роздільною здатністю 168×168 пікселі.


Для візуального порівняння роботи різних методів на рис. 4 наведено фрагменти збільшеного утричі зображення № 6 з рис. 2. Як видно з рис. 3, найкращі результати отримано для зображення, збільшеного методом на основі конволюційної нейронної мережі. Це ж підтверджується і при збільшенні усіх інших зображень тестової вибірки.



а) бікубічна інтерполяція



б) метод Янга



в) метод Зейде



г) градієнтні профілі



д) метод на основі НПС МГП



е) метод на основі КНМ

Рис. 3. Фрагменти збільшеного утричі зображення № 6 (з рис. 2), різними методами

У таблиці наведено значення співвідношення пікового сигналу до шуму (PSNR) для збільшених зображень тестової вибірки. Значення PSNR для усіх зображень підтвердили високу ефективність застосування методу на основі конволюційної нейронної мережі для забезпечення надвисокої роздільної здатності зображень.

Значення PSNR для збільшених утричі зображень різними методами

№ зображення	Бікубічна інтерполяція	Метод Янга	Метод Зейде	Гradientні профілі	Метод на основі НПС МГП	Метод на основі КНМ
1	32,2087	32,2087	33,1987	33,1987	33,1221	34,1431
2	31,6118	31,6218	31,6219	31,8	31,1465	32,4996
3	23,4473	23,4473	23,4474	23,81	23,2548	23,9121
4	27,4614	27,4614	27,4615	28,4	26,8106	28,9483
5	32,0252	32,0256	32,0257	32,94	31,0665	33,0799
6	26,7048	26,7051	26,7052	27,3	26,3758	27,73

Висновки

На основі проведеного огляду літературних джерел запропоновано класифікацію основних методів забезпечення надвисокої роздільної здатності у випадку одного вхідного зображення. В межах цього виділено переваги та недоліки сучасних методів забезпечення надвисокої роздільної здатності зображень на основі машинного навчання.

Встановлено, що процес збільшення РЗ зображень методами на основі технології реконструкції супроводжується розмитістю контурів, що визначають однорідні ділянки об'єктів на зображеннях, тому зумовлює необхідність застосування процедур post-обробки.

Виявлено, що основним недоліком окремих методів на основі навчання є неможливість роботи на вибірках малої розмірності. Це накладає додаткові умови на розмірність навчальної вибірки, а саме необхідність забезпечення великого набору навчальних даних і, відповідно, збільшення обчислювального навантаження в процесі навчання.

Ітеративні алгоритми навчання, які реалізуються на основі ШНМ, не забезпечують достатньої швидкості обчислень, а це, своєю чергою, накладає обмеження на їх застосування в практичних системах штучного інтелекту, що ґрунтуються на засадах технічного зору. Визначальною особливістю роботи методів цього класу є висока обчислювальна складність, що висуває високі вимоги до програмно-апаратного забезпечення. А тому актуальним завданням залишається пониження обчислювальних витрат із збереженням якості передискретизації зображень під час розв'язання задачі забезпечення надвисокої роздільної здатності зображень.

1. Rasrollahi K. *Super-resolution: a comprehensive survey* / K. Nasrollahi, T. B. Moeslund // *Machine Vision and Applications*. – 2014. – Vol. 25, № 6. – P. 1423–1468.
2. Xiong Z. *Robust web image-video super-resolution* / Z. Xiong, X. Sun, and F. Wu // *IEEE Transactions on Image Processing*. – 2010. – Vol. 19, № 9. – P. 2017–2028.
3. Sun J. *Image hallucination with primal sketch priors* / J. Sun, N. N. Zheng, H. Tao, and H. Y. Shum // *Computer Vision and Pattern Recognition: proc. of intern. conf., Madison, Wisconsin, 18–20 June 2003*. – IEEE: Computer Society, 2003. – Vol. 2. – P. 729–736.
4. Srivastava A. *On advances in statistical modeling of natural images* / A. Srivastava, A. B. Lee, E. P. Simoncelli, S.–C. Zhu // *Journal of Mathematical Imaging and Vision*. – 2003. – Vol. 18, № 1. – P. 17–33.
5. Ting Li *Image Super-Resolution using sharpened gradient profile prior: thesis.... master of science: electrical engineering* / Li, Ting. – Dallas, 2012. – 65 p.
6. Sun J. *Gradient profile prior and its applications in image super-resolution and enhancement* / J. Sun, J. Sun, Z. Xu, H. Y. Shum // *IEEE Transactions on Circuits and Systems for Video Technology*. – 2011. – Vol. 20, № 6. – P. 1529–1542.
7. Патент US 20100086227 (A1), США *Image super-resolution using gradient profile prior* / Jian Sun, Heung–Yeung Shum; Microsoft Corporation. – US 12/245,712; 04.10.2008; 08.08.2010.
8. Казакова Н. Ф. *Синтез методу виділення контурів у системах ідентифікації на основі усереднення перепадів*

яскравості / *Н. Ф. Казакова, О. О. Фразе-Фразенко // Інформаційна безпека. – 2013. – № 2. – С. 48–57.*

9. Yu L. Robust Single Image Super-resolution based on Gradient Enhancement / Licheng Yu, Hongteng Xu, Yi Xu, Xiaokang Yang // *Signal and Information Processing: annual summit and conf., Hollywood, CA, 3–6 Dec. 2012. – Asia-Pacific Signal and Information Processing Association, 2008. – P. 1 – 6.*

10. He He Single Image Super-Resolution using Gaussian Process Regression / He He, Wan-Chi Siu // *Computer Vision and Pattern Recognition: proc. of intern. conf., Colorado, USA, 20–24 June 2011. – IEEE: Computer Society, 2011. –P. 449–456.*

11. E. Mjolsness *Neural networks, pattern recognition, and fingerprint hallucination: thesis ... doctor of philosophy: 5198: TR:85 / Eric Mjolsness. – California, 1985. – 79 p.*

12. Datsenko D. Example-based single document image super-resolution: A global map approach with outlier rejection / D. Datsenko, M. Elad // *Journal of Multidimensional Systems and Signal Processing. – 2007. – № 2. – P. 103 – 121.*

13. Liu C. Face Hallucination: Theory and Practice / Ce Liu, Heung-Yeung Shum, William T. Freeman // *International Journal of Computer Vision. – 2007. – Vol. 75, № 1. – P. 115 – 134.*

14. Sua C. Steerable pyramid-based face hallucination / Congyong Sua, Yueting Zhuanga, Li Huang, Fei Wua // *Pattern Recognition. – 2005. – Vol. 38, № 6. – P. 813 – 824.*

15. J. Yang, J. Wright, T. Huang, and Y. Ma, “Image super-resolution as sparse representation of raw image patches,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Jun. 2008, pp. 1–8.*

16. R. Zeyde, M. Elad, and M. Protter, “On single image scale-up using sparse representations,” in *Curves and Surfaces. Springer, 2010.*

17. Freeman T. William Learning low-level vision / William T. Freeman, Egon C. Pasztor, Owen T. Carmichael // *International Journal of Computer Vision. – 2000. – Vol. 40, № 1. – P. 25 – 47.*

18. Gajjar Prakash Zoom Based Super-Resolution: A Fast Approach Using Particle Swarm Optimization / Prakash Gajjar, Manjunath Joshi // *Image and Signal Processing, Lecture Notes in Computer Science. – 2010. – Vol. 6134. – P. 63 – 70.*

19. E. Mjolsness *Neural networks, pattern recognition, and fingerprint hallucination: thesis ... doctor of philosophy: 5198: TR:85 / Eric Mjolsness. – California, 1985. – 79 p.*

20. Nguyen Q. M. Superresolution mapping using a Hopfield neural network with LIDAR data / Minh Quang Nguyen, Peter M. Atkinson, Hugh G. Lewis // *Geoscience and Remote Sensing Letters. – 2005. – Vol. 2, № 3. – P. 366–370.*

21. Nguyen Q. M. Superresolution Mapping Using a Hopfield Neural Network With Fused Images / Minh Quang Nguyen, Peter M. Atkinson, Hugh G. Lewis // *IEEE Transaction on geoscience and remote sensing. – 2002. – Vol. 40, № 3. – P. 736–749.*

22. Thornton M. W. A linearised pixel-swapping method for mapping rural linear land cover features from fine spatial resolution remotely sensed imagery / M. W. Thornton, P. M. Atkinson, and D. A. Holland // *Computers & Geosciences. – 2007. – Vol. 33, № 10. – P. 1261–1272.*

23. Pan F. New image super-resolution scheme based on residual error restoration by neural networks. / F. Pan, L. Zhang // *Optical Engineering. – 2003. – Vol. 42, № 10 – P. 3038–3046.*

24. Dong C. Image Super-Resolution Using Deep Convolutional Networks / Dong Chao, Loy Chen Change, He Kaiming, Tang Xiaoou // *IEEE Transactions on Pattern Analysis and Machine Intelligence, Preprint. – 2015. – P. 14.*

25. Ізонін І.В. Нейромережевий метод зміни роздільної здатності зображень / І. В. Ізонін, Р. О. Ткаченко, Д. Д. Пелешко, Д. А. Батюк // *Системи обробки інформації. – 2015. – Вип. 9(134). – С. 30–34.*

26. Izonin I. Learning-based image super-resolution using weight coefficients of synaptic connections / Ivan Izonin, Roman Tkachenko, Dmytro Peleshko, Taras Rak, Danylo Batyuk // *Computer science and information technologies: proc. of X intern. scien. and techn. conf., 14–17 Sep. 2015 y., Lviv, Ukraine. – Lviv: Lviv Polytechnic Publishing House, 2015. – P. 25–29.*