

ВИДАЛЕННЯ КОМПОНЕНТІВ ДОЩУ З ОДИНОЧНИХ ЗОБРАЖЕНЬ З ВИКОРИСТАННЯМ РЕКУРЕНТНОЇ НЕЙРОННОЇ МЕРЕЖІ

Петров К. Е. – д-р. техн. наук, професор, завідувач кафедри інформаційних управляючих систем, Харківський національний університет радіоелектроніки, Харків, Україна.

Кириченко В. В. – магістр кафедри штучного інтелекту, Харківський національний університет радіоелектроніки, Харків, Україна.

АНОТАЦІЯ

Актуальність. Видалення небажаних наслідків дощових ефектів з одиночних зображень є актуальною проблемою в багатьох задачах комп'ютерного зору, оскільки смуги дощу можуть суттєво погіршувати візуальну якість зображень та серйозно перешкоджати роботі різноманітних інтелектуальних систем, які використовуються для їх обробки та подальшого аналізу.

Мета роботи полягає у розробці методу виявлення і видалення небажаних наслідків впливу ефекту дощу з одиночних зображень, який базується на використанні згорткової нейронної мережі з рекурентною структурою.

Метод. Головною складовою запропонованого методу є згорткова нейронна мережа, яка має рекурентну багатоетапну структуру. Особливістю саме такої архітектури мережі є використання повторюваних блоків (шарів), на виході яких можна отримати проміжний результат «очищення» вихідного зображення. Причому на виході кожного наступного шару мережі отримуємо зображення з меншим впливом компонентів дощу ніж на попередньому. Кожен шар мережі містить дві незалежні підмережі (гілки) для паралельної обробки зображення. Головна гілка призначена для виявлення і видалення ефекту дощу з зображення, а гілка уваги використовується для покращення і пришвидшення процесу виявлення небажаних компонентів дощу (для формування карти уваги дощу).

Результати. Розроблено підхід до автоматичного виявлення та видалення наслідків впливу ефекту дощу з одиночних зображень. Процес «очищення» вихідного зображення здійснюється на основі використання згорткової нейронної мережі з рекурентною структурою, навчання якої було проведено на наборах даних Rain100H і Rain100L. Наведено результати комп'ютерних експериментів, які свідчать про ефективність та доцільність використання запропонованого методу для вирішення практичних завдань з попередньої обробки «забруднених» зображень.

Висновки. Перевагою розробленого методу видалення небажаних компонентів дощу з зображень є те, що рекурентна багатоетапна архітектура мережі, на якій він базується, дозволяє потенційно застосовувати його для вирішення завдань в умовах обмежених обчислювальних ресурсів. Запропонований метод може бути успішно використаний при розробці інтелектуальних систем для моніторингу територій за допомогою камер спостереження, автономного керування транспортними засобами, обробки результатів аерофотозйомки тощо. В перспективі слід розглянути можливість формування окремої підмережі для усунення розмитості на зображенні та провести навчання мережі на наборах даних, які містять зразки зображень з різними компонентами дощу, що зробить метод більш «стійким» до різних форм ефекту дощу і підвищить якість «очищення» зображень.

КЛЮЧОВІ СЛОВА: обробка зображень, ефект дощу, смуги дощу, глибинне навчання, згорткова нейронна мережа, механізм уваги.

АБРЕВІАТУРИ

CNN – convolutional neural network (згорткова нейронна мережа);

GAN – generative adversarial network (генеративна змагальна мережа);

LSTM – long short-term memory (довга короткострокова пам'ять);

MAE – mean absolute error (середня абсолютна похибка);

MSE – mean squared error (середня квадратична похибка);

PSNR – peak signal-to-noise ratio (співвідношення пікового рівня сигналу до шуму);

RAB – residual attention block (залишковий блок уваги);

ReLU – rectified linear units (зрізаний лінійний вузол);

RNN – recurrent neural network (рекурентна нейронна мережа);

SSIM – structural similarity index measure (індекс структурної подібності).

НОМЕНКЛАТУРА

a_i – підсумкова карта уваги зображення i на етапі t ;

F – «чистий» фон зображення;

L – функція загальних втрат;

L_M – функція втрат для головної гілки;

L_{SSIM} – функція втрат структурної подібності для головної гілки;

L_A – функція втрат гілки уваги;

m_i – бінарна карта регіонів дощу зображення i ;

N – кількість зображень;

P – зображення з ефектом дощу;

R – компоненти дощу (смуги чи краплі дощу або туман);

y_{ti} – вихід мережі на останньому етапі t (передбачене зображення i);

\tilde{y}_i – цільове «чисте» зображення i ;

$\|\cdot\|_1$ – L_1 -норма;

$\|\cdot\|_2$ – L_2 -норма.

ВСТУП

Серед наслідків природного впливу на зображення можна виокремити ефект дощу. Це можуть бути окремі краплі на об'єктиві камери, що зафіксовані на зображенні; рідкі чи навпаки щільні смуги (краплі в момент руху) дощу або ефект туману на задньому фоні.

Наявність смуг або крапель дощу на зображеннях та відео часто є небажаним. Негативний вплив ефекту дощу найбільш відчутний у сферах, які мають справу із обробкою зображень, що отримані зовні, наприклад, з камер зовнішнього спостереження, транспортних засобів, дронів, супутників тощо.

Задача виявлення та компенсації ефекту дощу є частиною більш глобальної проблеми «очищення» зображень від наслідків впливу погодних умов, таких як дощ, сніг або туман, яка в свою чергу відноситься до задач попередньої обробки.

Сам ефект дощу може по-різному впливати на зображення.

Це, по-перше, смуги дощу, які представляють собою краплі в момент руху, і перекривають об'єкти позаду, а щільні смуги можуть значною мірою закрити собою задній фон зображення. Їх побічним ефектом, у зв'язку з проходженням крізь них світла, є суттєве збільшення інтенсивності пікселів, які перекриваються краплями. По-друге, ефект туману або димки на задньому фоні, який виникає, коли густі смуги не можна відрізнити одна від одної на великій відстані від камери, що створює враження «зашумленості» та суттєво зменшує загальну контрастність зображення. По-третє, це наявність окремих крапель на об'єктиві камери, які також можуть значно перекривати об'єкти позаду і спотворювати зображення через переломлення світла крізь центральну частину краплі.

Тому для широкого спектру практичних застосувань потрібні ефективні методи видалення описаних вище компонентів дощу.

Методи для виявлення і видалення наслідків впливу ефекту дощу можна розділити на два основні класи [1]: підходи, які опрацюють послідовність кадрів (відео) і підходи, які застосовуються для обробки одиночних зображень. В методах для обробки відео активно використовується припущення про те, що серед всієї послідовності кадрів є хоча б один кадр, який не містить наслідків впливу дощу на конкретному пікселі або навіть області пікселів. Обробка одиночних зображень вважається більш складною задачею тому, що методи не можуть використовувати динаміку дощу, тобто його так звану «часову надлишковість», на відміну від методів обробки відео. Для опрацювання одиночних знімків використовують просторову інформацію сусідніх пікселів і візуальні властивості дощу та фону.

Роботу присвячено проблемі обробки саме одиночних зображень.

Незважаючи на наявність великої кількості існуючих методів щодо компенсації небажаного впливу ефекту дощу на зображеннях [1, 2] це завдання ще © Петров К. Е., Кириченко В. В., 2023
DOI 10.15588/1607-3274-2023-2-10

далеке від свого остаточного вирішення. Тому розробка нових методів для більш «якісної» та швидкої обробки «забруднених» небажаними компонентами дощу зображень є дуже актуальною.

Об'єктом дослідження є процес автоматичного виявлення і видалення наслідків впливу погодних ефектів при обробці зображень.

Предметом дослідження є методи виявлення і компенсації ефекту дощу при обробці одиночних зображень.

Мета роботи полягає у розробці методу виявлення і видалення небажаних наслідків впливу ефекту дощу з одиночних зображень, який базується на використанні апарату згорткових нейронних мереж з рекурентною структурою.

1 ПОСТАНОВКА ЗАДАЧІ

Вихідною інформацією для вирішення задачі виявлення та видалення небажаних компонентів дощу є деяке одиночне зображення P , що задане в форматі RGB.

Формалізовану модель «забрудненого» зображення P можна представити як накладання сцени F з «чистим» фоном і деяких компонентів дощу R (смуг чи крапель дощу або туману) у такому вигляді: $P = F + R$.

Компоненти дощу R , що накопичуються по всій сцені, зменшують видимість фону F .

Зображення P , що отримані в реальних умовах дощу суттєво ускладнюють їх подальшу обробку і, як наслідок, знижують продуктивність роботи алгоритмів комп'ютерного зору.

Задача полягає у вирішенні цієї проблеми, тобто у візуальному видаленні небажаних компонентів дощу R та перетворенні зображення з ефектом дощу P на «чисте» – F .

Основними проблемами на шляху успішного вирішення цього завдання є те, що по-перше, спочатку не задаються області, які закриті компонентами дощу, а по-друге, інформація про фонову сцену закритих регіонів в більшості випадків невідома. Також труднощі виникають коли структура та орієнтація об'єктів на зображенні схожі на компоненти дощу (смуги чи краплі). В цьому випадку важко одночасно видалити дощ і зберегти структуру зображення.

Для вирішення задачі виявлення та видалення небажаних компонентів дощу в роботі пропонується застосувати згорткову нейронну мережу з рекурентною багатоетапною структурою.

2 ОГЛЯД ЛІТЕРАТУРИ

Методи виявлення і компенсації ефекту дощу, що використовуються для обробки одиночних зображень можна поділити на два основні класи: підходи на основі моделі (методи, в яких не застосовується глибинне навчання) і підходи на основі даних [1].

Методи, що базуються на використанні моделі [1, 2], зазвичай покладаються на статистичний аналіз

проявів ефекту дощу (крапель, смуг, туману) та фонових сцен зображень. В них використовуються попередньо сформовані припущення, вводиться функція втрат і потім проводиться її оптимізація. Часто такі методи спираються на синтез певної математичної моделі, яка містить в собі фізичні властивості обраного виду ефекту дощу.

Серед підходів до вирішення завдання виявлення і видалення наслідків впливу ефекту дощу з одиночних зображень на основі моделі можна виділити дві базові стратегії: по-перше, це застосування керованих фільтрів (Guided Filter), а, по-друге, це використання попередньої інформації (Prior Information), яка у свою чергу також поділяється на кілька підкласів, серед яких можна виокремити групу методів розрідженого кодування і змішаних Гаусових моделі [1].

Методи із застосуванням керованого фільтра [1] зазвичай спочатку використовують хроматичну властивість смуг дощу, щоб отримати «грубий» фон. Після цього «грубий» фон використовують для фільтрації вхідного зображення з ефектом дощу, щоб у підсумку отримати відповідне зображення без нього. Наприклад, у роботі [3] була запропонована стратегія багатонаправленої фільтрації для видалення ефектів снігу чи дощу з одиночного зображення.

Методи на основі розрідженого кодування [1] використовують представлення вхідних векторів як розріджену лінійну комбінацію базисних векторів. Набір таких базисних векторів називається словником, який використовується для відновлення певного типу сигналів, наприклад сигналів смуг дощу або сигналів фону. З розрідженим кодуванням пов'язана спроба виявлення і компенсації ефекту дощу для одиночного зображення шляхом декомпозиції зображення за допомогою аналізу морфологічних компонентів [4]. Більш досконалий метод представлений в [5]. В ньому було запропоновано ввести властивість взаємовиключності в дискримінаційне розріджене кодування, з метою більш точного відокремлення шарів дощу і фону. Для поліпшення результатів в [6] було запропоновано побудувати ітераційний процес розділення шарів зображення для видалення смуг дощу з фонового шару і видалення деталей фонові текстури з шару смуг дощу.

Змішана Гаусова модель представляє собою ймовірнісну модель, в якій передбачається, що всі зразки даних згенеровані із кінцевого набору розподілів Гауса з невідомими параметрами. Таку змішану модель застосовують для моделювання як дощу, так і фонового шару [7]. Змішана модель фонового шару попередньо отримується з реальних зображень із різноманітними фоновими сценами. Змішана модель дощу формується на основі обраної області дощу з вхідного зображення, яка не має фонових текстур.

В цілому можна зробити висновок, що методи на основі моделі демонструють відносно непогані результати для зображень зі смугами дощу різних напрямків та розмірів, але погано обробляють ефект туману (наявність накопичення щільних смуг дощу на © Петров К. Е., Кириченко В. В., 2023
DOI 10.15588/1607-3274-2023-2-10

відстані), що значно обмежує можливості їх використання.

В теперішній час більш активно розвиваються підходи на основі даних. Суть таких методів полягає у застосуванні апарату глибоких нейронних мереж, і як наслідок, у необхідності тренування моделей на наборах даних, звідки і пішла назва даного класу. Серед них можна виділити групу методів, які використовують навчання з вчителем (Supervised Learning). До цієї групи відносять методи [1, 2], що базуються на використанні: CNN; RNN та багатоетапних структур (Multi-Stage Framework); моделей з мультимасштабною архітектурою (Multi-Scale Architecture); мереж з архітектурою типу «енкодер-декодер» (Encoder-Decoder Module); GAN. Окремо виділяють методи [1, 2], в яких використовується напівавтоматичне навчання (Semi-supervised Learning) та навчання без вчителя (Unsupervised Learning), а також різноманітні гібридні моделі, які одночасно використовують обидва підходи: як ті, що засновані на моделях, так і ті, що базуються на даних.

Розробка методів, що базуються на використанні CNN складає значну частину досліджень в галузі виявлення і видалення наслідків ефекту дощу. Однією з перших робіт, в якій використовувалася CNN була [8]. В ній описано застосування відносно неглибокої (трьохшарової) згорткової мережі для видалення з зображення бруду та крапель води з об'єктива камери чи скла. Пізніше, в [9] була представлена модель DerainNet на базі CNN, особливістю якої було розділення зображення на базовий (фоновий) шар і шар деталей. В [10] запропоновано глибоку мережу деталізації DDN (DetailNet) на основі ідеї глибокої залишкової мережі ResNet [11]. Недоліком цих методів є не достатньо гарні результати, що отримані на зображеннях з великими та щільними смугами дощу. Роботу [12] присвячено розробці методу виявлення і видалення дощу з урахуванням його щільності за допомогою багатопотокової щільної мережі DID-MDN, особливістю якої є опрацювання зображень з різними рівнями щільності смуг дощу. В [13] пропонується ідея використання просторової уважної мережі SPA-Net. Ці методи демонструють гарні результати у видаленні смуг дощу, але недостатньо якісно обробляють ефект накопичення дощу (ефект туману).

Головною особливістю рекурентних та багатоетапних структур [1, 2] є наявність окремих етапів обчислень всередині мережі. Архітектура таких моделей складається з повторюваних блоків, а наприкінці кожного етапу можна отримати проміжний вихід мережі, що дозволяє потенційно застосовувати ці методи для вирішення завдань з обмеженими обчислювальними ресурсами, оскільки можна відносно гнучко регулювати кількість ітерацій, тому що кожна наступна ітерація дає зображення з меншим впливом дощу, ніж попередня. Розглянемо найбільш відомі методи цієї групи. Це мережа для виявлення та видалення дощу JORDER [14, 15] та її модифікація JORDER-E [16], які дають гарні результати у випадку з щільними

смугами і накопиченням дощу, однак інколи можуть помилково видалити вертикальні текстури. Моделі для поступового видалення смуг дощу RESCAN [17], PRN та PReNet [18] які показують гарні результати на зображеннях зі смугами дощу різних напрямків та щільності, але недостатньо ефективно оброблюють накопичення дощу, а також інколи можуть розмивати фонові деталі зображення.

Ще одним напрямком досліджень є багатомасштабне навчання, суттю якого є одночасне використання різних масштабів зображення для виконання потрібної задачі. Наприклад, у роботі [19] пропонується розкласти задачу відновлення зображення на кілька підзадач за допомогою мережі LPNet. Головною перевагою методу є доволі високі показники його ефективності та відносна «легкість» моделі (близько 8 тис. параметрів), хоча за кількісними показниками LPNet поступається більш «важким» моделям, наприклад, такій як JORDER (більше 4 млн. параметрів).

Методи, що використовують архітектуру «енкодер-декодер» [2] гарно проявили себе в різних задачах обробки зображень. В цій архітектурі енкодер – мережа, яка приймає вхідні дані та виводить на їх основі карту (вектори) ознак. Декодер також є мережею, яка приймає на вхід вектор ознак від енкодера та забезпечує відповідність між виходом мережі і цільовим значенням. Наприклад, в роботі [20] представлено глибинну мережу DAF-Net з архітектурою такого типу, яка успішно справляється з видаленням як смуг, так і ефектів накопичення дощу, але іноді дещо розмиває фонові деталі.

Багато досліджень у галузі виявлення і компенсації ефекту дощу на зображеннях пов'язані з використанням GAN. Типова архітектура GAN складається з двох частин: генератора та дискримінатора, де дискримінатор намагається оцінити, чи є виданий генератором результат справжнім або фальшивим. Така реакція дискримінатора забезпечує додатковий зворотний зв'язок для оптимізації параметрів генератора для отримання візуально прийнятних результатів. В роботі [21] для вирішення проблеми застосовують умовну генеративну змагальну мережу ID-CGAN, яка складається з щільно-зв'язного генератора і багатомасштабного дискримінатора. Метод непогано видаляє смуги і накопичення дощу, але не завжди ефективно обробляє зображення зі смугами різної щільності та іноді може генерувати візуальні артефакти. В [22] представлено генеративну мережу з механізмом уваги для обробки ефекту саме щільно накопичених дощових крапель AttGAN. Тому його застосування для видалення смуг або накопичення дощу є доволі обмеженим.

Попри усі переваги і високу ефективність обробки зображень із різними типами дощових ефектів, розглянуті вище методи потерпають від обмежень парадигми навчання з вчителем. Їх основною проблемою є використання великої кількості тренувальних зразків, що значно збільшує трудомісткість процесу. Крім того, в більшості таких підходів використовується навчання на синтетичних зразках, що обмежує їх зда-
© Петров К. Е., Кириченко В. В., 2023
DOI 10.15588/1607-3274-2023-2-10

тність до узагальнення при обробці реальних зображень.

Для вирішення проблем, які пов'язані із використанням парадигми навчання з вчителем, застосовуються підходи на основі навчання без вчителя та напівавтоматичного навчання. Так, наприклад, в [23] представлено GAN для виявлення і компенсації ефекту дощу без вчителя UD-GAN, яка базується на введенні обмежень самонавчання і внутрішніх ознак, що отримані із непарних «чистих» зображень без дощу і «забруднених» зображень із наслідками ефекту дощу. Цей метод демонструє можливість виявляти і видаляти небажані наслідки дощу із зображень, але інколи може втрачати деякі деталі або генерувати візуальні артефакти особливо у випадках зі щільними смугами або накопиченням дощу.

У підходах, що базуються на напівавтоматичному навчанні достатньо поширеними є методи з одночасним використанням синтезованих парних і реальних непарних даних. Така стратегія хоча і зменшує витрати на отримання даних і знижує вплив перенавчання на синтезованих даних, але не завжди демонструє прийнятні результати при обробці реальних зображень.

Аналіз публікацій показує, що проблема виявлення і компенсації ефекту дощу є вельми актуальною та ще далека від свого остаточного вирішення. Використання для вирішення цієї проблеми численних різноманітних підходів, історію розвитку і детальний огляд яких представлено в [1, 2], спричинене бажанням дослідників розробити «універсальний» метод для видалення з зображень небажаних компонентів дощу різних видів. Тому розробка нових більш ефективних методів «очищення» зображень є достатньо актуальною.

3 МАТЕРІАЛИ І МЕТОДИ

Рекурентні та багатоетапні структури попри існуючі недоліки непогано зарекомендували себе у вирішенні завдань виявлення та видалення наслідків ефекту дощу. Їх головною перевагою над іншими методами є поступовість, тобто, на кожному етапі можна отримати проміжний результат, який з кожною наступною стадією буде покращуватися. Тому саме цей підхід до побудови структури штучної нейронної мережі було обрано в якості основи для розробки методу виявлення і компенсації ефекту дощу.

Розглянемо архітектуру мережі більш детально.

Мережа представляє собою рекурентну структуру, яка на кожному етапі здатна видавати повноцінний результат – «чисте» зображення без наслідків ефекту дощу. Кожен шар мережі складається з головної гілки, яка використовується для виявлення і видалення ефекту дощу та гілки уваги (Attention Branch), що призначена для покращення і пришвидшення процесу виявлення. Гілка уваги застосовується для формування карти уваги дощу, яка далі надходить до головної гілки. При цьому головна гілка ніяким чином не впливає на гілку уваги: обидві гілки на вхід отримують вхідне зображення (для першого етапу) або про-

міжний результат (для подальших етапів). Це забезпечує певний рівень автономності роботи обох підмереж і чіткіше визначає роль гілки уваги, як допоміжної підмережі.

Розгорнуте представлення загальної архітектури мережі наведено на рис. 1 (сірим кольором виділені межі одного окремого шару мережі). Головна гілка складається з шару згортки Conv з функцією нелінійного перетворення ReLU, шару LSTM, п'яти блоків RAB та вихідного шару згортки Conv.

У підсумку ця підмережа формує карту уваги, яка являє собою одноканальну матрицю зі значеннями у діапазоні $[0, 1]$. Вона вказує на просторовий розподіл дощу та використовується для керування процесом виявлення і видалення ефекту дощу у залишкових блоках уваги.

На вхід гілки уваги подається конкатенація проміжного результату попереднього етапу (трьохканальне зображення у форматі RGB) і значення попередньої маски (одноканальна матриця з такими ж просторовими розмірами) (рис. 1). Окремим випадком є перший етап: вхід для підмережі уваги формується з вхідного зображення і одноканальної матриці, заповненої значеннями 0,5.

Шар LSTM використовується для поширення ознак і їх взаємозалежностей між різними етапами для полегшення видалення смуг дощу. Залишкові блоки уваги виокремлюють потрібні в подальшому ознаки, керуючись картою уваги, отриманою від гілки уваги. Тобто, на вихід RAB впливає не лише вихід попереднього шару, а й результат, який отримано від гілки уваги. Також потрібно відмітити особливість залишкового навчання цієї мережі: вихідний шар згортки формує зображення, яке відповідає від'ємному шару дощу. Після додавання вхідного зображення на виході отримуємо «чисте» зображення без наслідків ефекту дощу.

Гілка уваги представляє собою окрему підмережу (рис. 2). Вона складається із шару згортки Conv з подальшим застосуванням функції ReLU. Далі йдуть п'ять залишкових блоків (Residual Block) та вихідний шар згортки Conv.

Ця гілка потрібна для захоплення просторової контекстної інформації з метою виділення ознак дощу:

смуг різного напрямку та щільності, крапель різної форми і т. п.

Приклади вхідного зображення з наявним ефектом дощу та візуалізація відповідної йому карти уваги з останнього етапу наведені на рис. 3.




Рисунок 2 – Архітектура гілки уваги




Рисунок 3 – Приклад вхідного зображення і відповідної йому карти уваги

Таким чином, гілка уваги дозволяє приблизно ідентифікувати регіони, що пошкоджені наслідками ефекту дощу. Через відносно просту структуру підмережі пряме використання отриманих карт може бути неефективним, оскільки крім областей дощу вони також можуть виділяти окремі деталі фонових текстур. Тому запропонована мережа застосовує карти уваги лише як додаткову інформацію для прискорення процесу виявлення регіонів дощу головною гілкою.

Головна підмережа містить в собі п'ять послідовних блоків RAB, кожен з яких складається з двох послідовних шарів згортки Conv і застосування функції ReLU та ще одного шару Conv, після якого отриманий результат перемножується з картою уваги (Attention map), яка надходить від гілки уваги. Далі до результату додається вхід блоку шляхом використання пропу-

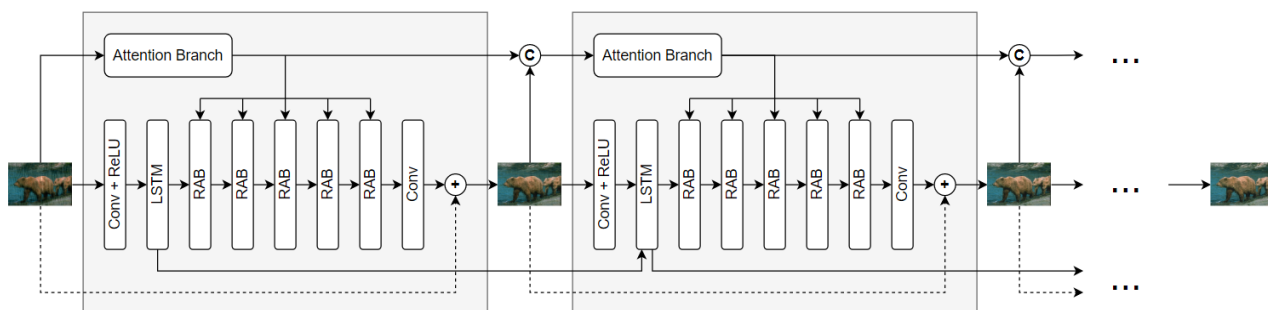


Рисунок 1 – Загальна архітектура запропонованої мережі

ського з'єднання. Після цього на виході ще раз застосовується функція ReLU (рис. 4). Також особливістю архітектури блоку є те, що друга згортка має коефіцієнт розширення, який дорівнює 2. Збільшення коефіцієнту допомагає охоплювати більший контекст інформації і, як наслідок, демонструвати вищу ефективність при однаковій глибині мережі.

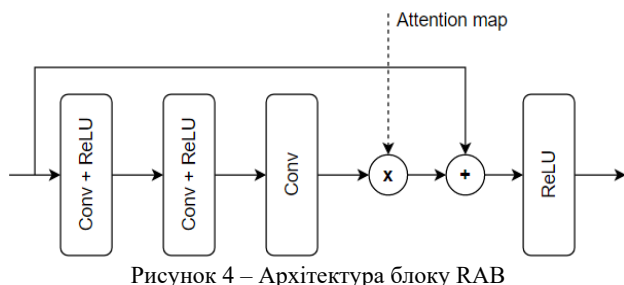


Рисунок 4 – Архітектура блоку RAB

Цей блок виокремлює ознаки, що необхідні для виявлення областей дощу та їх подальшого видалення. Після третьої згортки отримані ознаки перемножуються з картою уваги (рис. 4). Оскільки карта містить значення у діапазоні $[0, 1]$, це можна інтерпретувати як послаблення ознак, які на думку гілки уваги, не відносяться до регіонів дощу. Тим самим підмережа уваги регулює результат головної гілки.

Розглянемо тепер процес навчання запропонованої мережі.

Як було зазначено вище, особливістю запропонованої мережі є її рекурентна, поступова природа, а також наявність двох паралельних гілок обчислень. Це спонукає до формування комбінованої функції загальних втрат, яка б враховувала результати, що отримані від обох підмереж, з метою її подальшої мінімізації. Тому функцію загальних втрат L пропонується обчислювати за формулою:

$$L = L_M + L_{SSIM} + L_A. \quad (1)$$

Функція втрат L_M використовуються для вимірювання точності піксельного відновлення і дорівнює значенню MAE між виходом мережі і цільовими «чистими» зображеннями без ефекту дощу. Для мережі з t етапами, проміжними виходами y_1, y_2, \dots, y_{t-1} і кінцевим виходом y_t функція L_M розраховується за формулою:

$$L_M = \frac{1}{N} \sum_{i=1}^N \|y_{t_i} - \tilde{y}_i\|_1.$$

Значення L_{SSIM} використовується для регулювання структурної подібності між кінцевим виходом мережі y_{t_i} і цільовим зображенням \tilde{y}_i , $i = \overline{1, N}$ та обчислюється на основі індексу SSIM [25] таким чином:

$$L_{SSIM} = \frac{1}{N} \sum_{i=1}^N (1 - SSIM(y_{t_i}, \tilde{y}_i)).$$

На відміну від піксельного порівняння з використанням MSE або MAE, індекс SSIM відображує ступінь подібності зображень як комбінацію трьох факторів: структури текстур, яскравості та контрасту. Ця особливість SSIM дозволяє краще оцінювати схожість з точки зору візуального сприйняття зображення людиною.

Для оптимізації параметрів гілки уваги застосовується функція втрат L_A . Її значення обчислюється, як піксельна різниця між підсумковою картою уваги a_t на етапі t та бінарною картою регіонів дощу m за допомогою MSE таким чином:

$$L_A = \frac{1}{N} \sum_{i=1}^N \|a_{t_i} - m_i\|_2^2.$$

Бінарна карта регіонів дощу – це матриця, що містить значення 0 та 1, де 1 вказує на те, що даний піксель «покритий» дощем, а 0 вказує на те, що піксель «чистий». Така бінарна карта може обчислюватися шляхом визначення порогової різниці між зображенням з дощем та «чистим» зображенням або напряму братися з набору даних, якщо він надає таку можливість. Приклад бінарної карти регіонів дощу для зображення представлений на рис. 5.

4 ЕКСПЕРИМЕНТИ

В якості наборів даних для проведення експериментальних досліджень були використані датасети Rain100H та Rain100L [14]. Обидва набори є синтезованими, але мають різні кількісні та якісні характеристики.



Рисунок 5 – Зображення та відповідна йому бінарна карта регіонів дощу

Набір Rain100H містить 1800 зображень різного розміру та пропорцій для навчання та 100 зображень для тестування з п'ятьма напрямками смуг дощу. В наборі Rain100L міститься 200 зображень для навчання та 100 зображень для тестування, але лише з одним типом смуг дощу. Обидва датасети крім синтезованих зображень з дощем і «чистих» оригіналів також містять бінарні карти регіонів дощу, які використовувалися під час тренування мережі.

Для практичної реалізації запропонованого підходу були використані мова програмування Python, фреймворк машинного навчання PyTorch, бібліотеки для обробки зображень OpenCV та scikit-image. Навчання мережі відбувалося з використанням можливостей хмарної платформи Google Colaboratory.

Як було зазначено вище, запропонована мережа складається з головної гілки і гілки уваги. Гілка уваги має такі параметри: кількість вхідних, прихованих та вихідних каналів. В запропонованій архітектурі гілка уваги приймає чотирьохканальну матрицю, а на виході отримує одноканальну. Для дотримання балансу між розміром моделі, часом її навчання і ефективністю роботи мережі було вирішено використати 32 приховані канали як для гілки уваги, так і для всіх інших модулів. В якості шару згортки використана стандартна згортка розміром 3×3 . Гілка уваги містить в собі п'ять залишкових блоків зі стандартними згортками розміром 3×3 . Головна гілка в свою чергу містить п'ять залишкових блоків уваги, в яких стандартна згортка 3×3 з коефіцієнтом розширення, що дорівнює 1 чергується зі згорткою з коефіцієнтом 2.

Повна мережа, що використовується для вирішення завдання виявлення і компенсації ефекту дощу для одиночних зображень включає в себе усі вищеописані модулі. Її параметрами є: кількість етапів та число прихованих каналів. Оптимальними значеннями для цих параметрів є 6 та 32 відповідно.

5 РЕЗУЛЬТАТИ

Для тренування мережі у набір Rain100H були внесені певні зміни: було виявлено, що 546 зображень з ефектом дощу з 1800 навчальних зразків мають такий самий вміст фону, як і тестові зображення [18]. Тому ці 546 зображень були виключені із тренувального набору, а для навчання моделі було використано решту 1254 зображень. Для збільшення тренувальних наборів навчання проводилося не на повнорозмірних зображеннях, а на областях розміром 100×100 . Тому розмір набору Rain100H зріс до 18810 зразків. Для Rain100L додатково застосовувалося горизонтальне відзеркалення, тому він виріс до 6000 зразків.

Розмір вхідного пакету становив 16 зображень. Для оптимізації процесу навчання мережі застосовувався метод Adam [26]. Початкова швидкість навчання становила 0,001. Запропонована модель навчалася протягом 30 епох на кожному з обраних наборів. Тривалість навчання однієї епохи на наборі Rain100H з використанням графічного процесора становила приблизно 20–25 хв. Графік зміни значення функції втрат (1) для запропонованої моделі з використанням набору Rain100H наведено на рис. 6.

В якості метрик для оцінки процесу та якості навчання мережі були обрані співвідношення PSNR [27] та індекс SSIM [25]. Графіки зміни значень PSNR і SSIM для запропонованої мережі з використанням набору Rain100H наведені на рис. 7 та 8 відповідно.




Рисунок 6 – Графік зміни значення функції загальних втрат для Rain100H




Рисунок 7 – Графік зміни значення PSNR для Rain100H




Рисунок 8 – Графік зміни значення SSIM для Rain100H

Також, на основі обчислення значень PSNR і SSIM було проведене порівняння запропонованої моделі з іншими відомими методами, які широко використовуються для виявлення і видалення наслідків ефекту дощу з одиночних зображень: JORDER [14], RESCAN [17] та PReNet [18].

Варто зазначити, що на відміну від інших методів, для JORDER метрики напряму обчислювались за результатами, що були отримані в [18]. Результати тестування методів представлені в табл. 1.

Таблиця 1 – Результати тестування методів

Набори даних	Методи							
	JORDER		RESCAN		PReNet		Запропонований метод	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Rain100H	25,22	0,801	27,54	0,842	27,65	0,875	27,66	0,874
Rain100L	35,25	0,968	35,32	0,969	35,76	0,973	35,78	0,971

Візуальне порівняння якості обробки («очищення») зображення з використанням різних методів на прикладі зображення з набору Rain100H представлено на рис. 9.

Крім цього, також було проведено візуальне порівняння якості обробки реальних зображень з ефектом дощу різними методами.

Оскільки для методу JORDER не було можливості використати натреновану модель, він не приймав участі у порівнянні. Для інших методів були протестовані моделі, які були навчені на наборі Rain100H. Результати обробки на прикладі реальних зображень з ефектом дощу представлені на рис. 10.

6 ОБГОВОРЕННЯ

Аналіз отриманих результатів дозволяє зробити висновок, що запропонований метод демонструє достатньо непогані результати порівняно з іншими. Він показує вищі результати, ніж JORDER та RESCAN за показниками обох метрик: PSNR і SSIM (табл. 1). В порівнянні з PReNet метод показує кращі результати за оцінкою PSNR, але трохи гірші за індексом SSIM (табл. 1).

Слід відмітити, що розроблена модель програє RESCAN і PReNet у «розмірах». Вона має 226 тис. параметрів, JORDER – більше 4,1 млн., RESCAN – близько 150 тис., а PReNet – близько 95 тис. Цей факт впливає на ефективність її застосування з точки зору використання обчислювальних ресурсів.

Візуальне порівняння отриманих результатів свідчить про те, що запропонований метод демонструє набагато кращі результати з точки зору сприйняття людини порівняно з JORDER або RESCAN і трохи краще за PReNet (рис. 9).




Рисунок 9 – Візуальне порівняння якості обробки зображення різними методами




Рисунок 10 – Візуальне порівняння якості обробки реальних зображень різними методами

Розроблена модель достатньо непогано видаляє смуги дощу, але може генерувати певні артефакти, як показано в області зображення, що виділена червоною рамкою (рис. 9) або розмивати текстури, як показано в регіонах, які виділені зеленою та рожевою рамками (рис. 9).

Із отриманих результатів візуального порівняння якості обробки реальних зображень різними методами (рис. 10) можна побачити, що запропонований метод не завжди видаляє всі смуги дощу та інколи розмиває фоніві текстури. Також він має певні труднощі з обробкою ефекту туману (накопичення дощу), але це пов'язано з тим, що навчальна вибірка майже не містила зразків з ефектом подібного типу. Разом з тим, реалізована модель дає набагато кращі візуальні результати ніж RESCAN. У порівнянні ж з PReNet складно зробити однозначний висновок, методи демонструють приблизно однакову візуальну якість результату (рис. 10).

Таким чином постає питання про подальше вдосконалення методу для отримання кращих результатів.

ВИСНОВКИ

В роботі запропоновано метод розв'язання актуального завдання виявлення і видалення небажаних наслідків ефекту дощу з одиночних зображень, який базується на використанні згорткової нейронної мережі з рекурентною багатоетапною структурою та механізму уваги.

До переваг розробленого підходу слід віднести «модульну» структуру нейронної мережі, яка використовується для «очищення» зображення. Архітектура такої мережі складається з повторюваних блоків (шарів) і на виході кожного шару здатна видавати повноцінний результат – «чисте» зображення без наслідків ефекту дощу. Тобто на виході кожного наступного шару мережі ми отримуємо більш «якісно очищене»

зображення від небажаних компонентів дощу ніж попереднє, що дозволяє підвищити продуктивність та ефективність використання запропонованого методу. Це підтверджують результати експериментальних досліджень.

В результаті тестування метод показав достатньо високі значення показників PSNR (27,66 та 35,78) і SSIM (0,874 та 0,971) для наборів даних Rain100N та Rain100L відповідно. Отримані результати суттєво перевищують показники таких методів як JORDER або RESCAN. Порівняно з PReNet запропонований метод демонструє вищі значення PSNR і показує невелику перевагу у якісних результатах візуального сприйняття зображення, але при цьому отримує трохи менші значення SSIM та має «більший розмір».

Наукова новизна роботи.

1. Вперше запропоновано метод виявлення та видалення компонентів дощу з одиночних зображень, який базується на використанні рекурентної багатоетапної структури нейронної мережі. Кожен шар мережі складається з двох гілок (підмереж) для незалежної (паралельної) обробки зображення: головної гілки, яка використовується для виявлення і видалення ефекту дощу та гілки уваги, що призначена для покращення і пришвидшення процесу виявлення (формування карти уваги дощу). Багатоетапна архітектура мережі дозволяє потенційно застосовувати цей метод для вирішення завдань в умовах обмежених обчислювальних ресурсів, оскільки вона дозволяє відносно гнучко регулювати кількість етапів (шарів), тому що кожний наступний етап дає зображення з меншим впливом дощу, ніж попередній.

2. Удосконалено процес навчання мережі завдяки введенню комбінованої функції загальних втрат (1), яка враховує результати, що отримані від обох підмереж (паралельних гілок обчислень).

Практична значимість результатів роботи полягає в тому, що запропонований підхід може бути успішно застосований в якості попереднього етапу автоматизації процесу обробки зображень в інтелектуальних системах різного спрямування. Зокрема, систем, які використовуються для аналізу транспортних потоків, моніторингу території за допомогою камер зовнішнього спостереження, навігації на дорозі для систем автономного керування транспортними засобами, обробки результатів аерофотозйомки тощо.

Перспективи подальших досліджень. Подальший розвиток розробленого методу пов'язаний з дослідженням можливості використання структури пов'язаних між собою щільнозв'язаних блоків та впровадження кількох паралельних підмереж для реалізації багатомасштабної архітектури. Також доволі перспективним є формування окремої підмережі для усунення розмитості на зображенні та її об'єднання з основною гілкою мережі, що зробить модель більш «стійкою» до різних форм ефекту дощу при обробці зображень. Для підвищення кількісних і якісних показників ефективності методу доцільно провести навчання мережі на наборах даних, що містять зразки зображень з різними типами ефекту дощу.

ПОДЯКИ

У роботі висвітлено результати, що були отримані авторами у 2021–2022 роках в рамках виконання держбюджетного науково-дослідного проекту «Глибокі гібридні системи обчислювального інтелекту для аналізу потоків даних та їх швидке навчання» (номер державної реєстрації 0119U001403) на кафедрі штучного інтелекту Харківського національного університету радіоелектроніки.

Автори вдячні колегам за підтримку під час дослідження та активну участь в обговоренні результатів.

ЛІТЕРАТУРА

1. Wang H. Survey on rain removal from videos or a single image / H. Wang, Y. Wu, M. Li, Q. Zhao, D. Meng // *Science China Information Sciences*. – 2022. – Vol. 65(1): 111101. DOI:10.1007/s11432-020-3225-9
2. Single image deraining: from Model-based to Data-driven and beyond / [W. Yang, R. T. Tan, S. Wang et al.] // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2021. – Vol. 43, № 11. – P. 4059–4077. DOI: 10.1109/TPAMI.2020.2995190
3. Single-image-based rain and snow removal using multi-guided filter / [X. Zheng, Y. Liao, W. Guo et al.] // *20th International Conference on Neural Information Processing (ICONIP-2013)*, Doegu, 03–07 November, 2013: proceedings. – Berlin: Springer, 2013. – P. 258–265. (Lecture Notes in Computer Science, Vol 8228). DOI: 10.1007/978-3-642-42051-1_33
4. Kang L.-W. Automatic single-image-based rain streaks removal via image decomposition / L.-W. Kang, C.-W. Lin and Y.-H. Fu // *IEEE Transactions on Image Processing*. – 2012. – Vol. 21, № 4. – P. 1742–1755. DOI: 10.1109/TIP.2011.2179057
5. Luo Y. Removing rain from a single image via discriminative sparse coding / Y. Luo, Y. Xu, H. Ji // *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, 07–13 December, 2015: proceedings. – P. 3397–3405. DOI: 10.1109/ICCV.2015.388
6. Joint bi-layer optimization for single-image rain streak removal / [L. Zhu, C.-W. Fu, D. Lischinski, P.-A. Heng] // *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, 22–29 October, 2017: proceedings. – P. 2545–2553. DOI: 10.1109/ICCV.2017.276
7. Rain streak removal using layer priors / [Y. Li, R. T. Tan, X. Guo et al.] // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27–30 June, 2016: proceedings. – P. 2736–2744. DOI: 10.1109/CVPR.2016.299
8. Eigen D. Restoring an image taken through a window covered with dirt or rain / D. Eigen, D. Krishnan, R. Fergus // *2013 IEEE International Conference on Computer Vision (ICCV)*, Sydney, 01–08 December, 2013: proceedings. – P. 633–640, DOI: 10.1109/ICCV.2013.84
9. Clearing the skies: A deep network architecture for single-image rain removal / [X. Fu, J. Huang, X. Ding et al.] // *IEEE Transactions on Image Processing*. – 2017. – Vol. 26, № 6. – P. 2944–2956. DOI: 10.1109/TIP.2017.2691802
10. Removing rain from single images via a deep detail network / [X. Fu, J. Huang, D. Zeng et al.] // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21–26 July, 2017: proceedings. – P. 1715–1723. DOI: 10.1109/CVPR.2017.186
11. Deep residual learning for image recognition / [K. He, X. Zhang, S. Ren, J. Sun] // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27–30 June, 2016: proceedings. – P. 770–778. DOI: 10.1109/CVPR.2016.90
12. Zhang H. Density-aware single image de-raining using a multi-stream dense network / H. Zhang, V. M. Patel // *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, 18–23 June, 2018: proceedings. – P. 695–704. DOI: 10.1109/CVPR.2018.00079
13. Wang T. Spatial attentive single-image deraining with a high quality real rain dataset / [T. Wang, X. Yang, K. Xu et al.] // *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15–20 June, 2019: proceedings. – P. 12262–12271. DOI: 10.1109/CVPR.2019.01255
14. Deep joint rain detection and removal from a single image / [W. Yang, R. T. Tan, J. Feng et al.] // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21–26 July, 2017: proceedings. – P. 1685–1694. DOI: 10.1109/CVPR.2017.183
15. Yu F. Multi-scale context aggregation by dilated convolutions / F. Yu, V. Koltun // *4th International Conference on Learning Representations (ICLR-2016)*, San Juan, 02–04 May, 2016: proceedings. – P. 1–13. DOI: 10.48550/arXiv.1511.07122
16. Joint rain detection and removal from a single image with contextualized deep networks / [W. Yang, R. T. Tan, J. Feng et al.] // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2020. – Vol. 42, № 6. – P. 1377–1393. DOI: 10.1109/TPAMI.2019.2895793
17. Recurrent squeeze-and-excitation context aggregation net for single image deraining / [X. Li, J. Wu, Z. Lin et al.] // *15th European Conference Computer Vision (ECCV-2018)*, Munich, 08–14 September, 2018: proceedings. – Cham: Springer, 2018. – P. 262–277. – (Lecture Notes in Computer Science, Vol. 11211). DOI: 10.1007/978-3-030-01234-2_16

18. Ren D. Progressive image deraining networks: A better and simpler baseline / [D. Ren, W. Zuo, Q. Hu et al.] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, 15–20 June, 2019: proceedings. – P. 3932–3941. DOI: 10.1109/CVPR.2019.00406
19. Lightweight pyramid networks for image deraining / [X. Fu, B. Liang, Y. Huang et al.] // IEEE Transactions on Neural Networks and Learning Systems. – 2020. – Vol. 31, № 6. – P. 1794–1807. DOI: 10.1109/TNNLS.2019.2926481
20. Depth-attentional features for single-image rain removal / [X. Hu, C.-W. Fu, L. Zhu et al.] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, 15–20 June, 2019: proceedings. – P. 8014–8023. DOI: 10.1109/CVPR.2019.00821
21. Zhang H. Image de-raining using a conditional generative adversarial network / H. Zhang, V. Sindagi, V. M. Patel // IEEE Transactions on Circuits and Systems for Video Technology. – 2020. – Vol. 30, № 11. – P. 3943–3956. DOI: 10.1109/TCSVT.2019.2920407
22. Attentive generative adversarial network for raindrop removal from a single image / [R. Qian, R. T. Tan, W. Yang et al.] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, 18–23 June, 2018: proceedings. – P. 2482–2491. DOI: 10.1109/CVPR.2018.00263
23. Jin X. Unsupervised single image deraining with self-supervised constraints / [X. Jin, Z. Chen, J. Lin et al.] // 2019 IEEE International Conference on Image Processing (ICIP), Taipei, 22–25 September, 2019: proceedings. – P. 2761–2765. DOI: 10.1109/ICIP.2019.8803238
24. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9, № 8. – P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
25. Image quality assessment: from error visibility to structural similarity / [Z. Wang, A. C. Bovik, H. R. Sheikh, E. P. Simoncelli] // IEEE Transactions on Image Processing. – 2014. – Vol. 13, № 4. – P. 600–612. DOI: 10.1109/TIP.2003.819861
26. Kingma D. P. Adam: A method for stochastic optimization / D. P. Kingma, J. Ba // 3rd International Conference on Learning Representation (ICLR-2015), San Diego, 07–09 May, 2015: proceedings. P. 1–15. DOI: 10.48550/arXiv.1412.6980
27. Huynh-Thu Q. Scope of validity of PSNR in image/video quality assessment / Q. Huynh-Thu, M. Ghanbari // Electronics letters. – 2008. – Vol. 44, №13. – P. 800–801. DOI: 10.1049/el:20080522

Стаття надійшла до редакції 25.01.2023.
Після доробки 07.05.2023.

UDC 004.932

REMOVAL OF RAIN COMPONENTS FROM SINGLE IMAGES USING A RECURRENT NEURAL NETWORK

Petrov K. E. – Dr. Sc., Professor, Head of the Department of Information Control Systems, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine.

Kyrychenko V. V. – Master Student of the Department of Artificial Intelligence, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine.

ABSTRACT

Context. Removing the undesirable consequences of rain effects from single images is an actual problem in many computer vision tasks, because rain streaks can significantly degrade the visual quality of images and seriously interfere with the operation of various intelligent systems, which are used for their processing and further analysis.

Objective. The goal of the work is to develop a method for detecting and removing undesirable effects of the rain from single images, which is based on the using of a convolutional neural network with a recurrent structure.

Method. The main component of the proposed method is a convolutional neural network, which has a recurrent multi-stage structure. A feature of this network architecture is the use of repeated blocks (layers), at the output of which you can get an intermediate result of «cleaning» the original image. Moreover at the output of each next layer of the network we get an image with less influence of rain components than on the previous one. Each network layer contains two independent sub-networks (branches) for parallel image processing. The main branch is designed to detect and remove the effect of rain from the image and the attention branch is used to improve and speed up the process of detecting undesirable rain components (for rain attention map formation).

Results. An approach has been developed to automatically detect and remove the rain effect from single images. The process of «cleaning» the original image is based on the use of a convolutional neural network with a recurrent structure, which was trained on the Rain100H and Rain100L datasets. The results of computer experiments, which testifies to the effectiveness and expediency of using the proposed method for solving practical tasks of pre-processing «contaminated» images are presented.

Conclusions. The advantage of the developed method for removing undesirable components of rain from images is that the recurrent multi-stage network architecture, on which it is based allows it to be potentially applied to solving tasks under conditions of limited computing resources. The proposed method can be successfully used in the development of intelligent systems for area monitoring with surveillance cameras, autonomous vehicles control, processing aerial photography results, etc. In the future, it should be considered the possibility of forming a separate sub-network to eliminate blurring in the image and train the network on datasets that contain image samples with different components of rain, which will make the method more «resistant» to different forms of the rain effect and increase the quality of image «cleaning».

KEYWORDS: image processing, rain effect, rain streaks, deep learning, convolutional neural network, attention mechanism.

REFERENCES

1. Wang H. Wu Y., Li M., Zhao Q., Meng D. Survey on rain removal from videos or a single image, *Science China Information Sciences*, 2022, Vol. 65(1), 111101. DOI:10.1007/s11432-020-3225-9
2. Yang W., Tan R. T., Wang S., Fang Y., Liu J. Single image deraining: from Model-based to Data-driven and beyond, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, Vol. 43, № 11, pp. 4059-4077. DOI: 10.1109/TPAMI.2020.2995190

3. Zheng X., Liao Y., Guo W., Fu X., Ding X. Single-image-based rain and snow removal using multi-guided filter, *20th International Conference on Neural Information Processing (ICONIP-2013)*, Doegu, 03–07 November, 2013, proceedings. Berlin, Springer, 2013, pp. 258–265. (Lecture Notes in Computer Science, Vol 8228). DOI: 10.1007/978-3-642-42051-1_33
4. Kang L.-W., Lin C.-W. and Fu Y.-H. Automatic single-image-based rain streaks removal via image decomposition, *IEEE Transactions on Image Processing*, 2012, Vol. 21, № 4, pp. 1742–1755. DOI: 10.1109/TIP.2011.2179057
5. Luo Y., Xu Y., Ji H. Removing rain from a single image via discriminative sparse coding, *2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago, 07–13 December, 2015, proceedings, pp. 3397–3405. DOI: 10.1109/ICCV.2015.388
6. Zhu L., Fu C.-W., Lischinski D., Heng P.-A. Joint bi-layer optimization for single-image rain streak removal, *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, 22–29 October, 2017, proceedings, pp. 2545–2553. DOI: 10.1109/ICCV.2017.276
7. Li Y., Tan R. T., Guo X., Lu J., Brown M. S. Rain streak removal using layer priors, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, 27–30 June, 2016, proceedings, pp. 2736–2744. DOI: 10.1109/CVPR.2016.299
8. Eigen D., Krishnan D., Fergus R. Restoring an image taken through a window covered with dirt or rain, *2013 IEEE International Conference on Computer Vision (ICCV)*. Sydney, 01–08 December, 2013, proceedings, pp. 633–640. DOI: 10.1109/ICCV.2013.84
9. Fu X., Huang J., Ding X., Liao Y., Paisley J. Clearing the skies: A deep network architecture for single-image rain removal, *IEEE Transactions on Image Processing*, 2017. Vol. 26, No. 6, pp. 2944–2956. DOI: 10.1109/TIP.2017.2691802
10. Fu X. Huang J., Zeng D., Huang Y., Ding X., Paisley J. Removing rain from single images via a deep detail network, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, 21–26 July, 2017, proceedings, pp. 1715–1723. DOI: 10.1109/CVPR.2017.186
11. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, 27–30 June, 2016, proceedings, pp. 770–778. DOI: 10.1109/CVPR.2016.90
12. Zhang H., Patel V. M. Density-aware single image de-raining using a multi-stream dense network, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, 18–23 June, 2018: proceedings, pp. 695–704. DOI: 10.1109/CVPR.2018.00079
13. Wang T. Yang X., Xu K., Chen S., Zhang Q., Lau R. W. H. Spatial attentive single-image de-raining with a high quality real rain dataset, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15–20 June, 2019: proceedings, pp. 12262–12271. DOI: 10.1109/CVPR.2019.01255
14. Yang W. Tan R. T., Feng J., Liu J., Guo Z., Yan S. Deep joint rain detection and removal from a single image, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, 21–26 July, 2017, proceedings, pp. 1685–1694. DOI: 10.1109/CVPR.2017.183
15. Yu F., Koltun V. Multi-scale context aggregation by dilated convolutions, *4th International Conference on Learning Representations (ICLR-2016)*. San Juan, 02–04 May, 2016: proceedings, pp. 1–13. DOI: 10.48550/arXiv.1511.07122
16. Yang W., Tan R. T., Feng J., Guo Z., Yan S. and Liu J. Joint rain detection and removal from a single image with contextualized deep networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, Vol. 42, № 6, pp. 1377–1393. DOI: 10.1109/TPAMI.2019.2895793
17. Li X., Wu J., Lin Z., Liu H., Zha H. Recurrent squeeze-and-excitation context aggregation net for single image de-raining, *15th European Conference Computer Vision (ECCV-2018)*, Munich, 08–14 September, 2018, proceedings. Cham: Springer, 2018, pp. 262–277. (Lecture Notes in Computer Science, Vol. 11211). DOI: 10.1007/978-3-030-01234-2_16
18. Ren D., Zuo W., Hu Q., Zhu P., Meng D. Progressive image de-raining networks: A better and simpler baseline, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15–20 June, 2019, proceedings, pp. 3932–3941. DOI: 10.1109/CVPR.2019.00406
19. Fu X., Liang B., Huang Y., Ding X., Paisley J. Lightweight pyramid networks for image de-raining, *IEEE Transactions on Neural Networks and Learning Systems*, 2020, Vol. 31, № 6, pp. 1794–1807. DOI: 10.1109/TNNLS.2019.2926481
20. Hu X., Fu C.-W., Zhu L., Heng P.-A. Depth-attentional features for single-image rain removal, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, 15–20 June, 2019, proceedings, pp. 8014–8023. DOI: 10.1109/CVPR.2019.00821
21. Zhang H., Sindagi V., Patel V. M. Image de-raining using a conditional generative adversarial network, *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, Vol. 30, № 11, pp. 3943–3956. DOI: 10.1109/TCSVT.2019.2920407
22. Qian R., Tan R. T., Yang W., Su J., Liu J. Attentive generative adversarial network for raindrop removal from a single image, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, 18–23 June, 2018, proceedings, pp. 2482–2491. DOI: 10.1109/CVPR.2018.00263
23. Jin X., Chen Z., Lin J., Chen Z., Zhou W. Unsupervised single image de-raining with self-supervised constraints, *2019 IEEE International Conference on Image Processing (ICIP)*. Taipei, 22–25 September, 2019, proceedings. pp. 2761–2765. DOI: 10.1109/ICIP.2019.8803238
24. Hochreiter S., Schmidhuber J. Long short-term memory, *Neural Computation*, 1997, Vol. 9, № 8, pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
25. Wang Z., Bovik A. C., Sheikh H. R., Simoncelli E. P. Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, 2014, Vol. 13, № 4, pp. 600–612. DOI: 10.1109/TIP.2003.819861
26. Kingma D. P., Ba J. Adam: A method for stochastic optimization, *3rd International Conference on Learning Representation (ICLR-2015)*, San Diego, 07–09 May, 2015, proceedings, pp. 1–15. DOI: 10.48550/arXiv.1412.6980
27. Huynh-Thu Q., Ghanbari M. Scope of validity of PSNR in image/video quality assessment, *Electronics letters*, 2008, Vol. 44, № 13, pp. 800–801. DOI: 10.1049/el:20080522