

# АНСАМБЛЕВІ МЕТОДИ НА ОСНОВІ ЦЕНТРУВАННЯ ДЛЯ СЕГМЕНТАЦІЇ ЗОБРАЖЕННЯ

*В.Д. Конюхов*

Інститут енергетичних машин і систем ім. А. М. Підгорного НАН України,  
відділ вібраційних і термоміцнісних досліджень

*E-mail: [sugrimov@ipmach.kharkov.ua](mailto:sugrimov@ipmach.kharkov.ua)*

© Конюхов В.Д. 2024

Ансамблеві методи можуть використовуватись для багатьох завдань, одними з найпопулярніших є: класифікація, регресія та сегментація зображень. Сегментація зображень є складною задачею, де використання ансамблевих методів машинного навчання дає можливість покращити точність передбачень нейронних мереж.

В цьому дослідженні було запропоновано три нові методи комбінування передбачень нейронних мереж, які були порівнянні з ансамблевим методом усереднення та звичайним використанням нейронних мереж. Дані методи базуються на ідеї центрування масок та різних методів комбінування передбачень. Основна мета дослідження – створити більш надійні та якісні ансамблеві методи, які зможуть виконувати свої завдання незалежно від якості зображення. Дані методи основані на різних підходах, що дає змогу обирати більш підходящий метод для вирішення конкретної задачі. Завдяки використанню запропонованих методів була отримана гарна ефективність сегментації медичних зображень на різних даних. Отримані результати вказують на те, що запропоновані методи комбінування передбачень дають змогу мінімізувати загальну помилку, краще узагальнювати дані та підвищити надійність використання передбачень.

**Ключові слова:** ансамблеві методи, глибоке навчання, машинне навчання, сегментація зображення.

## 1. Вступ

В сучасному світі сегментація зображень за допомогою машинного навчання набула великої популярності. Завдяки використанню методів машинного навчання стало можливим покращити автоматизацію процесів сегментації зображень. Сегментацію зображень почали використовувати в медичній сфері, в автономних транспортних засобах, робототехніці та інших сферах. Але сегментація зображень стикається з різними викликами в процесі своєї роботи: якість зображень, артефакти, шуми, алгоритми сегментації та інше. Для вирішення цих завдань було запропоновано ансамблеві методи, які поєднують переваги машинного навчання та покращують точність сегментації.

Основна ідея використання ансамблевих методів полягає в використанні різної кількості передбачень та їх подальшого об'єднання. Завдяки чому ансамблевий метод поєднує в собі якості використаних нейронних мереж, що дає більш стійкі результати. Кожна нейронна мережа дістає характеристики зображення по-різному, а використання ансамблю дає змогу не тільки використовувати одну архітектуру, а й велику кількість різних архітектур. Це в свою чергу дає можливість об'єднати різні підходи до сегментації зображень та значно покращити точність, що дуже важливо в медичних задачах, де існує велика кількість зображень поганої якості, а надійність і якість передбачень відіграють важливу роль.

В даній статті розглядаються нові ансамблеві методи, які були протестовані на трьох наборах даних.

## **2. Огляд літературних джерел**

Методи машинного навчання встигли зарекомендувати себе як якісні та надійні способи сегментації зображень. Але ідеального методу немає, а необхідність підвищення якості і точності сегментації залишається. Ансамблеві методи стали новою віхою поліпшення машинного навчання. Саме вони сприяють поліпшенню продуктивності та зменшенню ризику перенавчання. Однією з перших робіт пов'язаних з ансамблями нейронних мереж була робота Бреймана в якій він запровадив ідею бегінга (Bootstrap Aggregating) [1]. У своїй статті автор пропонує метод, який складається з декількох моделей, заснований на різних підвиборках даних, результатом якого є об'єднання їх передбачень. Наступним піонером у цій галузі був Дітеріх, який у своїй статті описав основні методи ансамблювання, такі як: бегінг, бустинг та стекінг [2]. Аналіз взаємозв'язку між узагальнюючою здатністю ансамблю та кореляцією окремих показав що у деяких випадках ансамблювання вибіркової підмножини одиночних мереж перевершує ансамбль всіх окремих мереж [3]. У статті [4] автори запропонували свою альтернативу Байєсівським нейронним мережам. Запропонований ними варіант був простий у реалізації, легко паралелізується, вимагає малого налаштування параметрів і дає якісний приріст передбачуваної оцінки. Мохаммед і Кора у своїй роботі надали всебічний розширений огляд різних методів ансамблів нейронних мереж [5]. Вони вивчили останні тенденції в ансамблевому навчанні з використанням кількісного аналізу, а також запропонували деякі фактори, які безпосередньо впливають на успішність ансамблів.

Основну увагу варто приділити перевагам застосування ансамблевих методів у задачах сегментації зображень. Хан та інші [6] у своїй роботі запропонували гібридну нейронну мережу з використанням ансамблевої обробки для сегментації ядер аномальної форми. Отримані ними результати показують, що цей метод перевершує інші методи нейронних мереж. У статті [7] було представлено двошаровий ансамбль моделей глибокого навчання сегментації медичних зображень. Результати цього дослідження показали, що запропонований метод ансамблю поєднує сильні сторони і зменшує вплив недоліків складових методів сегментації. Застосування ансамблевих методів до завдання класифікації гіперспектральних методів описано у статті [8]. Використання великого спектру каналів дозволяє детальніше вивчити об'єкти. Автори поділяють методології глибокого навчання та глибокого навчання з ансамблем на спектральні ознаки, просторові ознаки та комбіновані ознаки для того, щоб всебічно оцінити прогрес таких методологій для гіперспектральних зображень. Фаска та інші у своїй роботі [9] запропонували ефективний метод ансамблевого навчання з використанням стекованого узагальнення для сегментації кольорових зображень. Вони використовували метод опорних векторів та бібліотеку для градієнтного бустингу (LightGBM), після чого вони об'єднували їх результати для остаточного прогнозу. Хо та інші у своєму дослідженні [10] використовували глибоке ансамблеве навчання для класифікації зображень сітківки ока. Отримані результати показали, що застосування ансамблевої мережі допомогло підвищити точність порівняно з найвищим показником окремої мережі. Дане дослідження вказує на користь застосування ансамблевих методів для очних патологій. Використання ансамблевого конвейера (VertXNet) для автоматичної сегментації та анотації хребців було досліджено у роботі [11]. Автори провели експерименти на трьох різних наборах даних, в результаті чого вони продемонстрували, що використання ансамблевого методу значно перевершує U-Net і Mask R-CNN. У своїй роботі автори статті [12] запропонували свій ансамблевий метод, який складався з трьох базових моделей, які були модифікаціями U-Net і блок, який об'єднував усі результати. Експериментальні результати показали, що застосування даного методу для сегментації ретинальних кіст покращило показник точності в порівнянні з існуючою моделлю SFU. Джіон та інші запропонували селективні ансамблеві методи [13]. Вони ранжували передбачення, отримані з кількох моделей, і накладали більшу вагу на прогнози з великими рангами. Запропоновані методи покращили точність сегментації.

## *Ансамблеві методи на основі центрування для сегментації зображення*

### **3. Постановка задачі**


Застосування автоматизації сегментації зображень потребує особливої надійності та точності у медичній сфері та інших серйозних областях. Існуючі нині ансамблеві методи хоч і показують хороші результати, але все одно стикаються з різними труднощами. Наявність шумів на зображеннях, погана стійкість до вхідних даних, все це лише посилюється на тлі невеликої кількості даних.

Основна мета даної роботи – розробка нових ансамблевих методів, які краще сприйнятливі до різного роду перешкод, а також підвищення точності та стабільності сегментації зображень. Для цього будуть виконані такі завдання:

- Аналіз методу центрування масок щодо середнього центру.
- Розробка нових ансамблевих методів заснованих на центруванні масок з використанням порогового методу, об'єднання масок, усереднення масок за формою.
- Оцінка ефективності запропонованих методів на трьох наборах даних із використанням метрики DICE.
- Порівняння нових методів з одиночними мережами та ансамблевим методом усереднення.

### **4. Навчання нейронних мереж**

Для проведення дослідження були використанні зображення з відкритих джерел [14-16]. Отримані дані було розподілені на три набори. Дані отримані з джерела [15-16] були рентгенівські зображення та маски легень. Даний набір було розділено на дві частини. Перша частина складалась з 703 зображень та масок лівої легені. Друга частина теж складалась з 703 зображень та масок правої легені. В обох випадках для тренування використовувались 633 зображень, решта була використанні для тестування. Третій набір даних містив тільки рентгенівські знімки [14], маски були домальовані автором окремо. Маска відтворювала область із чотирьох хребців. Цей набір складався із 190 оригінальних зображень, а також для нього було відтворено автоматичну генерацію зображень, до якої входили наступні операції: 1) випадкове обертання в градусах  $[-15, 15]$ ; 2) випадковий зсув у відсотках по вертикалі та горизонталі  $[-10, 10]$ ; 3) випадкове масштабування у відсотках  $[0,8, 1,2]$ ; 4) випадкова зміна яскравості  $[0,8, 1,2]$ ; 5) випадкова зміна контрасту  $[0,75, 1,5]$ . Це дало змогу розширити набір до 1140 зображень. Для тренування було виділено 1026 зображень, для тестування було використано 114 зображень. Всі зображення було в градації сірого та мали однаковий розмір  $512 \times 512$  пікселів. На рисунку 1 можна побачити приклад використаних зображень та масок для них.



*Рис. 1. Приклад зображень для навчання. Зліва-направо: права легеня, ліва легеня, область з чотирьох хребців.*

Для навчання використовувалась нейронна мережа Fcn8MobileNet. Використання даної мережі

*В.Д. Конюхов*

обумовлено її полегшеною архітектурою, яка швидко навчається при цьому зберігаючи високу продуктивність. Використовуючи перший набір даних було навчено 50 нейронних мереж. Для другого набору даних та третього було навчено по 10 мереж відповідно. В процесі навчання кількість епох становила 100, розмір партії становив 32, для запобігання навчання використовувався метод EarlyStopping, який запобігав перенавчанню, якщо значення втрати перевірки не покращилося протягом десяти епох.

## 5. Методи

### 5.1. Метод центрування масок

В основі всіх методів, які будуть запропоновані нижче, лежить метод центрування масок. Основна його ідея полягає в знаходженні середнього центру для всіх масок одного зображення та зміщення масок відносно середнього центру. Якщо ми візьмемо 10 нейронних мереж (приблизно однакових по точності) та зробимо 10 передбачень для одного зображення, ми зможемо побачити що в деяких випадках форми та положення масок значно відрізняються. Навіть мережі майже з однаковими показниками точності в результаті створюють різні передбачення. Саме це й спонукало для використання ансамблю нейронних мереж та створення методу центрування масок. Отримані маски-передбачення від різних мереж зможуть доповнити друг друга та покращити надійність моделі. Перш за все було запропоновано дві гіпотези: 1) чим більше нейронних мереж в ансамблі, тим менше відстань між середнім центром та центром еталонної маски; 2) чим менше відстань від середнього центру до центра передбачення тим більше показник DICE.

Для того щоб підтвердити чи спростувати ці гіпотези, потрібно дати поняття середнього центру. Для дослідження цих двох гіпотез використовувались 50 нейронних мереж які були навчені на першому наборі даних. Для початку дамо визначення середньому центру. Нехай дано  $n$  зображень  $\{I_1, I_2, \dots, I_n\}$ , де для кожного зображення існує центр мас  $\{C_1, C_2, \dots, C_n\}$ , де кожен центр мас має координати  $(x_i, y_i)$ . Середній центр можна отримати за формулою  $C_{mean} = (x_{mean}, y_{mean})$ , де

$$x_{mean} = \frac{1}{n} \sum_{i=1}^n x_i,$$

та

$$y_{mean} = \frac{1}{n} \sum_{i=1}^n y_i.$$

Для детального дослідження було обрано 10 ансамблів, які склалися з: 5, 10, 15, 20, 25, 30, 35, 40, 45, 50 нейронних мереж. В кожному тестовому зображенні відповідно до кількості нейронних мереж в ансамблі було отримано середній центр для об'єктів, після чого було обчислено відстань від середнього центру до еталонного центру маски. Середнє значення відстані для всіх зображень у ансамблі було записано у таблицю. Відстань поміж точками вимірювалась по формулі:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}.$$

Для вирішення другої задачі, для кожного зображення було використано 50 нейронних мереж навчених на першому наборі. Для кожного зображення було отримано відстань від центру об'єкта передбачення до середнього центру по 50 маскам. Також для кожного зображення було отримано коефіцієнт DICE. Для того щоб зрозуміти чи відстань від центра до середнього центра має вплив на DICE було використано коефіцієнт кореляції Пірсона, для визначення залежності відстані від центру об'єкта до середнього центру та коефіцієнту DICE. Коефіцієнт кореляції визначається за формулою:

### Ансамблеві методи на основі центрування для сегментації зображення

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

де  $n$  – кількість пар значень,  $x_i$  та  $y_i$  значення  $X$  та  $Y$ ,  $\bar{x}$  та  $\bar{y}$  середні значення вибірок  $X$  та  $Y$ .

Після того як було отримано середнє значення центрів, потрібно кожний об'єкт на масці змістити відносно середнього центру. На рисунку 2 можна візуально побачити аналіз алгоритму. На цьому малюнку біла маска – це еталонна маска намальована людиною. Контури навколо неї – це контури масок-передбачень. Світло-сірі хрестики – це центри масок-передбачень, темно-сірий хрестик це середній центр, а чорний хрестик – це центр еталонної маски. Як можна побачити на зображенні, контури відрізняються по формі, також по розкиду центрів масок-передбачень можна зрозуміти що звичайний алгоритм має деякі виклики в цьому випадку. Наочно можна побачити користь використання середнього центру. Середній центр знаходиться дуже близько до еталонного центру.




Рис. 2. Алгоритм центрування масок.

#### 5.2. Пороговий метод

Даний алгоритм використовує заздалегідь вказаний поріг  $T$  для визначення необхідної кількості пікселів які впливають на остаточне рішення, яким буде фінальний піксель. Цей метод дещо схожий на зважене усереднення, в якому кожній нейронній мережі надається вага  $i$  в залежності від її значення це буде впливати на результат усереднення. В даному методі пропонується завдяки використанню порогу визначати чи належить результуючий піксель до об'єкту чи до фону. Якщо значення більше або дорівнює порогу, то піксель відноситься до об'єкта, в протилежному випадку до фону. Спочатку використовується метод центрування масок, а потім вже сам пороговий метод. Алгоритм працює наступним чином, спочатку потрібно обчислити кількість пікселів які відносяться до класу об'єкта:

$$count = \sum_{i=1}^n = \begin{cases} 1, & I_i(x, y) = 255 \\ 0, & \text{інакше} \end{cases},$$

де  $n$  – кількість нейронних мереж в ансамблі,  $I_i(x, y)$  – значення пікселя в позиції  $(x, y)$ .

Після того як було отримано кількість пікселів які відповідають шуканому об'єкту, потрібно записати нове значення пікселя в результуюче зображення:

$$I_{res}(x, y) = \begin{cases} 255, & count \geq T \\ 0, & \text{інакше} \end{cases}.$$

В.Д. Конюхов

### 5.3. Метод об'єднання

Цей метод виконує об'єднання всіх передбачень в одне. Такий підхід дуже корисний коли є зображення низької якості і є велика кількість нейронних мереж, таким чином ми знижуємо вплив недоліків які були отримані в передбаченнях. Іноді передбачення можуть бути дуже поганої якості, особливо коли ми говоримо про рентгенівські зображення. Вплив артефактів, поганої експозиції та інших недоліків можуть спричинити створення таких передбачень, які по формі та площі взагалі не будуть відповідати еталонній масці. Але після операції об'єднання результат значно покращиться, так він не стане ідеальним, і він може і не буде відповідати еталонній масці але це буде найближчий результат до істини який можна отримати для зображень дуже низької якості. Спочатку потрібно застосувати метод центрування, а потім маски-передбачення об'єднуються по формулі:

$$I_{res} = \bigcup_{i=1}^n I_i,$$

де  $n$  – кількість нейронних мереж в ансамблі,  $I_i$  –  $i$ -те зображення.

### 5.4. Метод усереднення по формі масок

Основна відміна цього методу від звичайних методів усереднення полягає в тому що він працює безпосередньо з формою об'єкта. Він не виконує усереднення пікселів, він виконує усереднення самих форм об'єктів. В основі алгоритму лежить метод трансформації відстані, який обчислює мінімальну відстань від пікселю об'єкта до пікселя фону. Обчислення трансформації відстані для однієї маски має наступний вигляд:

$$d = dt(mask) - dt(\sim mask),$$

де  $dt()$  – функція трансформації відстані,  $\sim mask$  – інвертована маска.

Далі виконуємо обчислення для всіх масок:

$$d_{all} = \sum_{i=1}^n d(mask_i).$$

Для того щоб отримати усереднене зображення, ми сумуємо отримані результати, і якщо сума значень більше 0 то піксель набуває значення 255 і значення 0, якщо інший варіант. Це робиться за формулою:

$$I_{res} = d_{all} > 0.$$

Коефіцієнт Дайса-Соренсена (DICE) використовувався в цьому дослідженні для оцінки якості сегментації та був визначений за наступною формулою:

$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|}.$$

## 6. Результати дослідження

Для того щоб порівнювати ефективність запропонованих методів потрібно знати оцінку якості сегментації (DICE) для одиночних мереж. Для першого набору даних мінімальне значення склало – 0.9548, максимальне – 0.9598. Для другого набору даних мінімальне значення – 0.9486, максимальне – 0.9580. Останній набір даних мав такі результати, мінімальне – 0.894605, максимальне – 0.919152. Різниця між максимальними та мінімальними значеннями вказує на невеликий діапазон та свідчать про стабільність використаної моделі.

### Ансамблеві методи на основі центрування для сегментації зображення

Перш за все потрібно було перевірити гіпотезу про те, що “чим більше нейронних мереж в ансамблі, тим менше відстань між середнім центром і еталонним центром”. Результати представлені в таблиці 1.

Таблиця 1.

#### Визначення відстані між середнім центром та еталонним центром

| Тип відстані       | Кількість нейронних мереж в ансамблі |        |        |        |        |        |        |        |        |        |
|--------------------|--------------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                    | 5                                    | 10     | 15     | 20     | 25     | 30     | 35     | 40     | 45     | 50     |
| Евклідова відстань | 3.5889                               | 3.4932 | 3.4556 | 3.4599 | 3.4898 | 3.5094 | 3.4918 | 3.4906 | 3.4724 | 3.4776 |

Як можна побачити з отриманих результатів, постійне збільшення кількості нейронних мереж в ансамблі кардинально не зменшило відстань, що в свою чергу може значити, що запропонована гіпотеза вірна частково (до 15 мереж у ансамблі). Найкращий результат було отримано при використанні 15 мереж в ансамблі, таким чином це стало оптимальним значенням і подальше збільшення нейронних мереж не призводить до значних покращень.

Наступна гіпотеза про те, що “чим менше відстань від центру маски до середнього центру, тим більше коефіцієнт DICE”. Вона була спростована завдяки використанню коефіцієнта кореляції Пірсона. Отриманий результат склав 0.0269, це свідчить про те, що слабка позитивна залежність проглядається між змінними, але вона незначна та не може бути статистично важливою. Таким чином було зроблено висновок, що маски, центри котрих близько розташовані до еталонного центру можуть мати значення DICE менше ніж маски центри яких розташовані далі. Для цих двох гіпотез було використано 50 нейронних мереж, що стало достатньо для отримання необхідних результатів.

Нарешті, в таблиці 2 наведені результати використання запропонованих методів в порівнянні зі звичайним використанням нейронних мереж та використанням методу усереднення. Всі дані в таблиці є середнім значенням для всіх зображень. Використання ансамблів з 10 нейронних мереж показало гарний результат.

Таблиця 2.

#### Визначення ефективності запропонованих методів використовуючи метрику DICE

| Набір даних | Назва методу       |             |        |        |        |        |
|-------------|--------------------|-------------|--------|--------|--------|--------|
|             | Вихідні зображення | Усереднення | A      | B      | C      | D      |
| 1           | 0.9564             | 0.9606      | 0.9596 | 0.9628 | 0.9601 | 0.9638 |
| 2           | 0.9542             | 0.9593      | 0.9553 | 0.9598 | 0.9524 | 0.9610 |
| 3           | 0.9099             | 0.9250      | 0.9167 | 0.9274 | 0.8931 | 0.9282 |

*Примітка. В таблиці були використанні наступні скорочення: A – метод здвигу масок відносно середнього центру; B – пороговий метод, де  $T=7$ ; C – метод об'єднання масок; D – метод усереднення по формі масок.*

Дані показані в таблиці 2, свідчать про те що, метод усереднення по формі масок отримав найкращий результат. Навіть просте використання здвигу масок відносно середнього центру дало результат трохи кращий ніж використання одиночних мереж. Але потрібно розуміти що метод центрування масок перш за все був запропонований як фундамент для інших методів. Таким чином ми маємо тільки три методи комбінування масок. Якщо порівняти запропоновані методи з використанням одиночних нейронних мереж то в 7 випадках із 9 вони гарантували кращий результат. А в порівнянні з методом усереднення в 6 випадках із 9. Цей результат є дуже хорошим, навіть незважаючи на те що не вдалося отримати 100% результат. Слабкою ланкою в даних випадках був метод об'єднання. Як було зазначено в описі цього методу, він дуже гарно виконує свою роль коли використовується зображення низької якості, а в даних випадках використовувались нейронні мережі з гарним результатом, що не дало змогу цьому методу проявити себе.

В.Д. Конюхов

## 7. Висновки

Було запропоновано три методи комбінування передбачень нейронних мереж. Проведене дослідження показало, що використання ансамблю нейронних мереж покращує точність і ефективність сегментації. Кожен з методів має свої недоліки та переваги. Таким чином, можна обирати необхідний метод для конкретної задачі. Пороговий метод отримує покращення точності за рахунок об'єднання результатів різних моделей тільки в тому випадку якщо кількість пікселів об'єкта вища за поріг, це дає змогу використовувати різні нейронні мережі по точності, та не переживати, що мережі з поганою точністю зможуть вплинути на результат комбінування. Використання методу об'єднання дуже гарно підходить для медичних випадків з використанням рентгенівських знімків поганої якості, коли об'єкти на масках значно менше еталонних. Даний метод об'єднує всі маски та робить точність сегментації кращою за рахунок об'єднання об'єктів розташованих в різних місцях та збільшення фінального об'єкта. Останній метод усереднює форми об'єктів, це дає можливість згладити різницю між формами масок.

В цілому, розглянуті методи продемонстрували гарний результат в порівнянні з методом усереднення та використанням без ансамблевого підходу. Кожен з методів може бути застосований залежно від конкретної задачі.

## Список літератури

1. Breiman, L. (1996). *Bagging predictors*. *Mach Learn* 24, 123–140. <https://doi.org/10.1007/BF00058655>.
2. Dietterich, T.G. (2000). *Ensemble Methods in Machine Learning*. In: *Multiple Classifier Systems*. MCS 2000. *Lecture Notes in Computer Science*, vol 1857. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/3-540-45014-9\\_1](https://doi.org/10.1007/3-540-45014-9_1).
3. Zhou, Z., Wu, J., Jiang, Y., & Chen, S. (2001). *Genetic Algorithm based Selective Neural Network Ensemble*. *International Joint Conference on Artificial Intelligence*.
4. Lakshminarayanan, B., Pritzel, A., & Blundell, C. (2016). *Simple and Scalable Predictive Uncertainty Estimation using Deep Ensembles*. *Neural Information Processing Systems*. <https://doi.org/10.48550/arXiv.1612.01474>.
5. Mohammed, A., & Kora, R. (2023). *A comprehensive review on ensemble deep learning: Opportunities and challenges*. *Journal of King Saud University - Computer and Information Sciences*, 35(2), 757–774. <https://doi.org/10.1016/j.jksuci.2023.01.014>.
6. Han, Y., et al. (2023). *An ensemble method with edge awareness for abnormally shaped nuclei segmentation*. In *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (pp. 4315-4325). Vancouver, BC, Canada. <https://doi.org/10.1109/CVPRW59228.2023.00454>.
7. Dang, T., Nguyen, T. T., McCall, J., et al. (2024). *Two-layer ensemble of deep learning models for medical image segmentation*. *Cognitive Computation*, 16(1), 1141–1160. <https://doi.org/10.1007/s12559-024-10257-5>.
8. Ullah, F., Ullah, I., Khan, R. U., Khan, S., Khan, K., & Pau, G. (2024). *Conventional to deep ensemble methods for hyperspectral image classification: A comprehensive survey*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 3878–3916. <https://doi.org/10.1109/JSTARS.2024.3353551>.
9. Faska, Z., Khriissi, L., Haddouch, K., et al. (2023). *A robust and consistent stack generalized ensemble-learning framework for image segmentation*. *Journal of Engineering and Applied Science*, 70, 74. <https://doi.org/10.1186/s44147-023-00226-4>.
10. Ho, E., Wang, E., Youn, S., Sivajohan, A., Lane, K., Chun, J., & Hutnik, C. M. L. (2022). *Deep Ensemble Learning for Retinal Image Classification*. *Translational vision science & technology*, 11(10), 39. <https://doi.org/10.1167/tvst.11.10.39>.
11. Chen, Y., Mo, Y., Readie, A., et al. (2024). *VertXNet: An ensemble method for vertebral body segmentation and identification from cervical and lumbar spinal X-rays*. *Scientific Reports*, 14, 3341. <https://doi.org/10.1038/s41598-023-49923-3>.
12. Rahil, M., Anoop, B. N., Girish, G. N., Kothari, A. R., Koolagudi, S. G., & Rajan, J. (2023). *A deep ensemble learning-based CNN architecture for multiclass retinal fluid segmentation in OCT images*. *IEEE Access*, 11, 17241–17251. <https://doi.org/10.1109/ACCESS.2023.3244922>.
13. Park, J., Kweon, J., Kim, Y. I., Back, I., Chae, J., Roh, J. H., Kang, D. Y., Lee, P. H., Ahn, J. M., Kang, S. J., Park, D. W., Lee, S. W., Lee, C. W., Park, S. W., Park, S. J., & Kim, Y. H. (2023). *Selective ensemble methods for deep learning segmentation of major vessels in invasive coronary angiography*. *Medical physics*, 50(12), 7822–7839.



*Ансамблеві методи на основі центрування для сегментації зображення*

<https://doi.org/10.1002/mp.16554>.

14. Vindr.ai. (n.d.). Vindr.ai datasets: SpineXR. Vindr.ai. Retrieved from <https://vindr.ai/datasets/spinexr>

15. Jaeger, S., Karargyris, A., Candemir, S., Folio, L., Siegelman, J., Callaghan, F., Xue, Z., Palaniappan, K., Singh, R. K., Antani, S., Thoma, G., Wang, Y. X., Lu, P. X., & McDonald, C. J. (2014). Automatic tuberculosis screening using chest radiographs. *IEEE Transactions on Medical Imaging*, 33(2), 233–245. <https://doi.org/10.1109/TMI.2013.2284099>.

16. Candemir, S., Jaeger, S., Palaniappan, K., Musco, J. P., Singh, R. K., Xue, Z., Karargyris, A., Antani, S., Thoma, G., & McDonald, C. J. (2014). Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration. *IEEE Transactions on Medical Imaging*, 33(2), 577–590. <https://doi.org/10.1109/TMI.2013.2290491>.

## ENSEMBLE METHODS BASED ON CENTERING FOR IMAGE SEGMENTATION

*V.D. Koniukhov*

A. Pidhornyi Institute of Power Machines and Systems of NAS of Ukraine,  
Department of vibration and thermal strength research

*E-mail:* [sugrimov@ipmach.kharkov.ua](mailto:sugrimov@ipmach.kharkov.ua)

© Koniukhov V.D. 2024

**Ensemble methods can be used for many tasks, some of the most popular being: classification, regression, and image segmentation. Image segmentation is a challenging task, where the use of ensemble machine learning methods provides an opportunity to improve the accuracy of neural network predictions.**

**In this study, three new methods for combining neural network predictions were proposed, which were compared with the ensemble averaging method and the conventional use of neural networks. These methods are based on the idea of mask centering and different methods of combining predictions. The main goal of the research is to create more reliable and high-quality ensemble methods that can perform their tasks regardless of image quality. These methods are based on different approaches, which makes it possible to choose a more suitable method for solving a specific problem. Thanks to the use of the proposed methods, a good efficiency of segmentation of medical images on different data was obtained. The obtained results indicate that the proposed methods of combining predictions make it possible to minimize the overall error, better generalize the data and increase the reliability of using predictions.**

**Key words:** ensemble methods, deep learning, machine learning, image segmentation.