

Інтелектуальна діагностична система для радіонуклідного статичного обстеження

А. С. Рижова¹⁾, В. В. Москаленко²⁾

^{1), 2)} Сумський державний університет, вул. Римського-Корсакова, 2, м. Суми, Україна, 40007

Article info:

Paper received:

17 September 2015

The final version of the paper received:

01 December 2015

Paper accepted online:

10 December 2015

Correspondent Author's Address:

²⁾ systemscoders@gmail.com

Пропонується метод інформаційного синтезу вирішальних правил діагностичної системи для радіонуклідного статичного обстеження органів людини на гамма-камері в умовах незбалансованого обсягу навчальних вибірок класів розпізнавання. Розглядається формування вхідного математичного опису діагностичної системи. Розроблено алгоритми сегментації та класифікації сцинтиграфічних зображень на основі інформаційно-екстремального машинного навчання. Розроблені алгоритми ґрунтуються на адаптивному двійковому кодуванні значень ознак розпізнавання та оптимізації геометричних параметрів розбиття простору ознак на класи еквівалентності, контейнери яких відновлюються в радіальному базисі бінарного простору Хеммінга, в процесі максимізації інформаційної спроможності діагностичної системи. Як критерій функціональної ефективності діагностичної системи використано модифікацію інформаційного критерію за С. Кульбаком, що є функціоналом від першої та другої достовірностей рішень, що приймаються в робочому режимі системи. Як приклад реалізації запропонованих алгоритмів розглядається паралельна композиція інформаційно-екстремальних класифікаторів для оцінювання рівня ураження паренхіми нирок внаслідок інфекційних захворювань.

Ключові слова: сегментація зображень, класифікація, машинне навчання, інформаційний критерій, оптимізація, словник ознак, радіонуклідна діагностика, гамма-камера.

ВСТУП

Радіонуклідна діагностика призначена для розпізнавання патологічних процесів в органах і тканинах шляхом введення пацієнтові радіофармпрепарату та реєстрації гамма-квантів, що випромінюються ним. Основним пристроєм для проведення сцинтиграфічних досліджень є гамма-камера, яка може зафіксувати кінцевий розподіл радіофармпрепарату у вигляді статичного знімка або зібрати серію зображень з певним часовим кроком для відображення динаміки накопичення та виведення радіофармпрепарату [1]. При цьому статичне обстеження є одним із найбільш інформативних досліджень при ранній діагностиці патологій нирок, рецидивів та метастазів пухлин. Однак інтерпретація сцинтиграфічних зображень (сцинтиграм) часто викликає у лікаря-діагноста певні труднощі. Це пов'язано з тим, що сцинтиграми є складним типом напівтонових зображень, для яких характерні наявність шуму, зерен і плям, слабка контрастність та відсутність стабільних відмінностей окремих областей [2, 3]. Обробка цих даних є складною процедурою, в якій забезпечення високої достовірності діагностичного висновку потребує об'єднання колективних знань експертів. Тому застосування ідей і методів машинного навчання та розпізнавання образів є одним з перспективних підходів для обробки сцинтиграм [4].

Такий підхід передбачає синтез вирішальних правил на основі навчальної матриці, що об'єднує колективний досвід експертів, і дозволяє реалізувати автоматичну сегментацію та класифікацію зображень з метою формування високостовірного діагностичного висновку. Як показано у працях [4, 5] популярні методи машинного навчання такі, як машина опорних векторів, нейронні мережі, та класифікатор Байеса, не забезпечують високої достовірності діагностичних рішень, оскільки в практичних умовах обмеженого та незбалансованого обсягу навчальних вибірок вони ігнорують перетин класів у просторі ознак розпізнавання.

Мета статті – запропонувати метод інформаційного синтезу здатної навчатися діагностичної системи для радіонуклідного статичного обстеження нирок з метою визначення ступеня їх ураження в умовах обмеженого і незбалансованого набору навчальних даних.

ПОСТАНОВКА ЗАВДАННЯ

Нехай на основі множини статичних сцинтиграфічних зображень із виділеними областями нирки і її уражень (у випадку їх наявності) та відповідних експертних висновків сформовано апріорно класифіковану вибірку векторів ознак пікселя в зоні спосте-

реження $\{v_{i,k}^{\theta} | j = \overline{1, n}; i = \overline{1, N}, k = \overline{1, K}\}$ та алфавіт класів $\{T_k^o | k = \overline{1, K}\}$, що характеризує тип зони спостереження. При цьому клас T_1^o є базовим і відповідає зоні інтересу. Для зони інтересу задано алфавіт образів $\{\Phi_c^o | c = \overline{1, C}\}$, що характеризує ступінь ураження нирки, і відповідна апріорно класифікована вибірка векторів ознак контурів нирки та її уражень $\{y_{c,i}^{\theta} | j = \overline{1, n_c}; i = \overline{1, N}; c = \overline{1, C}\}$. Клас Φ_1^o є базовим і відповідає функціональному стану здорової нирки. Відома структура вектора параметрів функціонування діагностичної системи:

$$g = \langle w, \delta_{T,i}, \delta_{\Phi,i}, x_m, d_m \rangle, \quad (1)$$

де w – розмір вікна (в пікселях) при скануванні сцинтиграфічного зображення; $\delta_{T,i}, \delta_{\Phi,i}$ – параметри ширини поля контрольних допусків для i -ї ознаки класифікаторів зони спостереження та функціонального стану нирки відповідно; x_m – двійковий еталонний вектор класу $X_m^o \in \{T_k^o\} \cup \{\Phi_c^o\}$, що визначає геометричний центр його гіперсферичного контейнера; d_m – радіус контейнера класу $X_m^o \in \{T_k^o\} \cup \{\Phi_c^o\}$, що побудований у радіальному базисі бінарного простору ознак.

При цьому задано такі обмеження: $d(x_m \oplus x_{cm}) > d_m$, де $d(x_m \oplus x_{cm})$ – кодова відстань між двійковим еталонним (усередненим) вектором класу X_m^o та двійковим еталонним вектором сусіднього до нього класу X_{cm}^o ; $\delta_{T,i} \in [0; \delta_{\max}]$, $\delta_{\Phi,i} \in [0; \delta_{\max}]$.

Необхідно в процесі навчання діагностичної системи визначити оптимальні значення координат вектора параметрів функціонування g^* (1), що забезпечують максимальне значення усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності (КФЕ) навчання діагностичної системи:

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M \max_{\sigma_E} \{E_m\}. \quad (2)$$

Необхідно в робочому режимі діагностичної системи прийняти рішення про належність екзаменаційних реалізацій до одного з класів алфавіту зон спостереження $\{T_k^o\}$ та про відповідність екзаменаційних реалізацій, віднесених до зони інтересу T_1^o , одному з класів алфавіту функціональних станів нирки $\{\Phi_c^o\}$.

АЛГОРИТМ ФУНКЦІОНУВАННЯ ДІАГНОСТИЧНОЇ СИСТЕМИ

Першим етапом аналізу сцинтиграфічного зображення є сегментація з метою виділення зон інтересу – межі нирок та їх уражень. Для розв'язання задачі сегментації сцинтиграфічних зображень за-

пропоновано здійснювати класифікацію їх пікселів на основі вирішальних правил, синтезованих у процесі інформаційно-екстремального машинного навчання [6]. При цьому вектор ознак пікселя може включати як координати та яскравість цього пікселя і його околу, так і відстань до різних анатомічних структур, інформацію про симетрію та інші ознаки. Визначення розміру сканувального вікна при класифікаційній сегментації можна виконати у зовнішньому контурі оптимізації параметрів навчання діагностичної системи. Розмітку (ручну сегментацію) навчальних зображень здійснюють різні експерти з радіонуклідної діагностики нирок.

До початку етапу сегментації доцільно виконати фільтрацію від різного типу шумів. Найбільш загальним нелінійним фільтром є медіанний, який замінює інтенсивність кожного пікселя зображення медіанним значенням інтенсивності пікселів його околу. Проте застосування медіанного фільтра призводить до придушення верхніх просторових частот зображення, викликаючи розмиття країв, що несуть інформацію про морфологічні особливості діагностованих органів. При цьому області сцинтиграфічного зображення з більшими значеннями лічильника імпульсів мають більше значення відношення сигнал/шум і тому потребують меншого рівня згладжування порівняно з тими областями, де інтенсивність імпульсів менша. Тому розмір вікна фільтра, який визначає рівень згладжування, потрібно адаптувати до рівня і типу шуму. Розглянемо основні кроки відповідної реалізації адаптивної медіанної фільтрації статичних сцинтиграм [7].

1. Формуємо для пікселя з координатами (x, y) вікно Wxy розміром Sxy .

2. Для вікна Wxy обчислюємо різниці:

$$A1 := Z_{\text{med}} - Z_{\text{min}},$$

$$A2 := Z_{\text{med}} - Z_{\text{max}},$$

де Z_{med} – медіана інтенсивності пікселів у вікні Wxy ;

Z_{max} – максимальний рівень інтенсивності пікселів у вікні Wxy ;

Z_{min} – мінімальний рівень інтенсивності пікселів у вікні Wxy .

3. Якщо $A1 > 0$ та $A2 < 0$, то перехід до кроку 5, інакше збільшити вікно.

4. Якщо $Sxy < S_{\text{max}}$, де S_{max} – максимальне значення розміру вікна, то перехід до кроку 2.

5. Для вікна Wxy з поточним розміром Sxy обчислюємо різниці:

$$B1 := Z_{xy} - Z_{\text{min}},$$

$$B2 := Z_{xy} - Z_{\text{max}}.$$

6. Якщо $B1 > 0$ та $B2 < 0$, то залишаємо Z_{xy} незмінним, інакше $Z_{xy} := Z_{\text{med}}$, де Z_{med} – медіанне значення інтенсивності пікселів вікна Wxy з поточним розміром Sxy .

У цьому алгоритмі фільтрації підлягає лише той центральний елемент вікна, для якого значення медіани і значення сигналу в центрі вікна більші від мінімального і менші від максимального значень у цьому вікні. При цьому розмір вікна буде більший у фонових ділянках сцинтиграми. Застосування такого фільтра дозволяє видалити біполярну імпульсну заваду, забезпечує згладжування шумів і зменшує

придушення верхніх просторових частот на зображенні.

Для синтезу класифікатора ступенів ураження нирок у процесі інформаційно-екстремального навчання запропоновано попереднє формування ознак розпізнавання в процесі контурного аналізу сегментів нирок та їх уражень. Визначення контурів на сегментованому напівтоновому зображенні починається з виділення меж, тобто кривих на зображенні, вздовж яких відбувається різка зміна яскравості чи інших видів неоднорідності. Один із найбільш популярних методів виділення меж на очищених від шуму зображеннях реалізовано в алгоритмі Кенні (Canny) [8], де використовується фільтр на основі першої похідної від гаусіани. Щоб оперувати з одержаними контурами їх необхідно якимось чином закодувати, наприклад, зазначати вершини відрізків, що складають контур. У праці [9] запропоновано алгоритм топологічного структурного аналізу бінарних зображень, що здатний знаходити зовнішні та вкладені контури і визначати їх ієрархію вкладеності. Цей алгоритм реалізовано в безкоштовній бібліотеці машинного зору *opencv* [10]. Бібліотека містить функції апроксимації точок ламаними лініями, прямокутниками, колами чи еліпсами. Також присутні функції для обчислення довжини контурів в пікселях, чи площі контурів у пікселях квадратних. Це дозволяє реалізувати фільтрацію контурів малої площі, які не становлять інтересу для лікаря-діагноста.

Після поєднання результатів сегментації та контурного аналізу пропонується формувати такий словник ознак:

- 1) мінімальна відстань між контуром ураження та контуром нирки;
- 2) велика і мала півосі еліпса ураження;
- 3) відносна площа ураження;
- 4) відношення сумарної яскравості нирки до її відносної площі;
- 5) координата x центра ваги контуру ураження;
- 6) координата y центра ваги контуру ураження;
- 7) ексцентриситет еліпса, одержаного за апроксимації контуру ураження;
- 8) вік пацієнта;
- 9) абсолютна площа нирки;
- 10) довжина нирки, при її апроксимації прямокутником;
- 11) ширина нирки;
- 12) відношення сумарних яскравостей лівої та правої нирок;
- 13) пропорція уражень, які виходять за чотири середньоквадратичних відхилень у базі навчальних зразків нормального стану нирки.

Інформаційно-екстремальне машинне навчання полягає у трансформації апріорнонечіткого простору первинних ознак розпізнавання в чітку еквівалентність класів, контейнери яких відновлюються в радіальному базисі двійкового простору вторинних ознак (простір Хеммінга).

Алгоритм інформаційно-екстремального навчання діагностичної системи подається як двоциклічна ітераційна процедура пошуку глобального максимуму інформаційного КФЕ (2) у робочій (допустимій) області визначення його функції

$$\overline{E}_m^* = \max_{G_\delta} \left\{ \frac{1}{M} \sum_{m=1}^M \max_{\{d_m\} \in G_{d_m}} \{E_m\} \right\}, \quad (3)$$

де G_δ – допустима область значень параметра поля контрольних допусків δ ; G_E – робоча область визначення функції критерію \overline{E} ; $G_d \in [0; d(x_m \oplus x_c) - 1]$ – область допустимих значень параметра d_m , що обмежена міжцентровою кодовою відстанню $d(x_m \oplus x_c)$ до найближчого сусіднього кластера (класу) X_c^o .

Розглянемо реалізацію алгоритму інформаційно-екстремального навчання [6, 11], що реалізує найпростішу процедуру оптимізації меж нижнього $A_{H,i}$ та верхнього $A_{B,i}$ поля контрольних допусків для i -ї ознаки з подальшою послідовною оптимізацією геометричних параметрів розбиття простору ознак.

1) обнулення лічильника кроків зміни параметра рецептивного поля $\delta : l := 0$;

2) $l := l + 1$;

3) на кожному кроці зміни параметра рецептивного поля обчислюються нижня $A_{H,i}[l]$ та верхня $A_{B,i}[l]$ межі кодувального рецептивного поля для всіх ознак розпізнавання за формулами

$$A_{H,i}[l] = y_{1,i} - \delta[l]; \quad A_{B,i}[l] = y_{1,i} + \delta[l], \quad (4)$$

де $y_{1,i}$ – вибіркове середнє значення i -ї ознаки в навчальній матриці класу X_1^o ;

4) формується бінарна навчальна матриця $\|x_{m,i}^{(j)}\|$ за правилами:

$$x_{m,2^*i-1}^{(j)} = \begin{cases} 1, & \text{if } A_{H_i}[l] < y_{m,i}^{(j)} < A_{B_i}[l], \\ 1, & \text{if } y_{m,i}^{(j)} \geq A_{B_i}[l], \\ 0, & \text{if } y_{m,i}^{(j)} \leq A_{H_i}[l]; \end{cases}$$

$$x_{m,2^*i}^{(j)} = \begin{cases} 1, & \text{if } A_{H_i}[l] < y_{m,i}^{(j)} < A_{B_i}[l], \\ 0, & \text{if } y_{m,i}^{(j)} \geq A_{B_i}[l], \\ 1, & \text{if } y_{m,i}^{(j)} \leq A_{H_i}[l]; \end{cases}$$

5) для класу X_m^o обчислюється двійковий еталонний вектор x_m за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > 0,5, \\ 0, & \text{if } \text{else}; \end{cases}$$

6) для множини векторів $\{x_m\}$ формується структурована множина елементів попарного розбиття $\{\mathfrak{R}_m^2 = \langle x_m, x_c \rangle\}$, що задає план навчання. Тут x_c – еталонний вектор найближчого класу X_c^o .

7) обчислюється для кожного класу X_m^o значення інформаційного КФЕ навчання діагностичної системи [6]:

$$E_m = [D_{1,m} + D_{2,m} - 1]^* \log_2 \left(\frac{D_{1,m} + D_{2,m}}{2 - [D_{1,m} + D_{2,m}]} \right), \quad (5)$$

де $D_{1,m}$ – перша достовірність для класу X_m^o ;
 $D_{2,m}$ – друга достовірність;

8) обчислюється за формулами (1) і (3) усереднене значення критерію $\bar{E}[l]$;

9) якщо $\delta \leq \delta_{\max}$, то виконується пункт 2, інакше – пункт 10;

$$10) \bar{E}^*[l] := \max_{\{l\}} \bar{E}[l];$$

$$11) \delta^* := \arg \bar{E}^*[l];$$

12) для параметра δ^* обчислюються за формулами (4) оптимальні нижні $\{A_{H,i}^*\}$ і верхні $\{A_{B,i}^*\}$ межі поля контрольних допусків на ознаки розпізнавання;

13) визначаються оптимальні радіуси контейнерів класів розпізнавання:

$$d_m^* = \arg E_m^*[\delta^*],$$

де $E_m^*[\delta^*]$ – максимальне значення КФЕ навчання діагностичної системи розпізнавати реалізації класу X_m^o , обчислене при оптимальному параметрі поля допусків δ^* ;

14) ЗУПИН.

Робоча (допустима) область визначення функції інформаційного критерію обмежена нерівностями $D_{1,m} \geq 0,5$, $D_{2,m} \geq 0,5$.

Для зручності порівняння результатів машинного навчання в рамках інформаційно-екстремальної інтелектуальної технології використовують нормовану модифікацію критерію (5), яку подають у вигляді

$$E_m^{(k)'} = \frac{E_m^{(k)}}{E_{\max}}, \quad (6)$$

де E_{\max} – максимальне граничне значення критерію (3), обчислене при: $D_{1,m}^{(k)} = 1$ та $\beta_m^{(k)} = 0$.

Накопичені в процесі медичної діагностики дані часто мають великий обсяг зі значною незбалансованістю класів, що обмежує застосування більшості методів машинного навчання. Однією з простих технік врахування незбалансованості є збільшення «премій» за правильну і збільшення «штрафів» за помилкову класифікацію реалізацій меншоритарних класів [12]. Це збільшує чутливість до рідкісних подій (наприклад, рідкісні захворювання чи аномальні функціональні стани діагностованого органа і т. д.), розпізнавання яких має більшу цінність, однак одночасно зменшується сумарна точність розпізнавання. Для підвищення точності класифікації реалізацій незбалансованих класів розпізнавання також застосовують методи послідовної (boosting) чи пара-

лельної (bagging) композиції ансамблю класифікаторів, що навчаються на різних підвбірках. Розмір одержуваної композиції класифікаторів залежить від використовуюваного методу машинного навчання. Перевагою поєднання ІЕІ-технології з методом паралельної композиції класифікаторів є можливість реалізації розпаралеленого, зокрема розподіленого, навчання та екзамену з підвищеною точністю за алгоритмом із відносно невисокою обчислювальною складністю, що сприяє зростанню загальної оперативності системи.

Кожен базовий класифікатор використовує один і той самий алгоритм, проте навчається за різними даними. Прогноз у композиції класифікаторів здійснюється шляхом комбінування результатів прогнозу кожного окремого класифікатора за допомогою зваженого голосування – прогнозованим класом є той клас, за який «проголосувало» більшість базових класифікаторів.

Алгоритм екзамену окремого класифікатора ґрунтується на аналізі значень функції належності, яка обчислюється для кожної реалізації, що розпізнається, визначаючи належність до контейнера класу X_m^o . Функція належності має геометричний сенс і обчислюється за формулою

$$\mu_m = 1 - \frac{d(x_m^* \oplus x^{(j)})}{d_m^*},$$

де $d(x_m^* \oplus x^{(j)})$ – кодова відстань між еталонним вектором x_m^* і реалізацією класу, що розпізнається; d_m^* – оптимальний радіус контейнера класу X_m^o .


Таким чином, навчання діагностичної системи полягає в оптимізації параметрів композиції класифікаторів на етапах сегментації та формування діагностичного висновку в процесі пошуку глобального максимуму інформаційного критерію в робочій області визначення його функції.

РЕЗУЛЬТАТИ ФІЗИЧНОГО МОДЕЛЮВАННЯ


Розглянемо результати реалізації запропонованих алгоритмів на прикладі навчання діагностичної системи для статичних нефросцинтиграфічних досліджень. Вибіркові дані складаються із сцинтиграфічних зображень, що зберігаються в репозиторії медичних зображень кластерного комплексу в Інституті сцинтиляційних матеріалів НАН України і подані у форматі DICOM. Для кожного із зображень медичними експертами сформовано діагностичний висновок про ступінь ураження в балах і додатково сформовано маски, що виділяють область нирок та області уражень перенхіми внаслідок інфекційних захворювань сечової системи. У цьому дослідженні алфавіт діагностичного висновку має два класи розпізнавання, що характеризують ступінь ураження за системою якісних оцінок Φ_1^o – «НОРМА» та Φ_2^o – «АНОМАЛІЯ». При цьому для класу Φ_1^o зібрано 1 050 зображень, а для класу Φ_2^o – 125 зображень.

На рисунку 1 показано графіки залежності усередненого нормованого інформаційного КФЕ від розміру сканувального вікна при класифікаційній

сегментації. При цьому для балансування класів міноритарний клас доповнювався дублікатами векторів-реалізацій. Штрихована ділянка позначає (тут і далі) робочу область визначення інформаційного КФЕ.



а



б

Рисунок 1 - Залежність усередненого значення КФЕ (6) класифікатора при сегментації: а – нирок; б – уражень

Аналіз рис. 1 показує, що оптимальний розмір вікна для виділення сегмента нирки становить 7×7 пікселів, для виділення сегментів уражень оптимальний розмір вікна становить теж 7×7 пікселів. При цьому максимум усередненого нормованого інформаційного КФЕ при сегментації області нирки становить $E^* = 0,321$. Максимум усередненого нормованого інформаційного КФЕ при сегментації областей ураження становить $E^* = 0,242$. Тобто інформаційний критерій на етапі сегментації не досягає свого граничного значення. На рисунку 2 показано процес оптимізації меж полів контрольних допусків за процедурою (3), за якої значення параметра полів контрольних допусків змінюється для всіх ознак одночасно. Пунктирна лінія (тут і далі) позначає зміну значень точності класифікатора на повному наборі апріорно класифікованих даних із незбалансованими класами. Точність A виражається відношенням

кількості правильно класифікованих спостережень до їх загальної кількості.

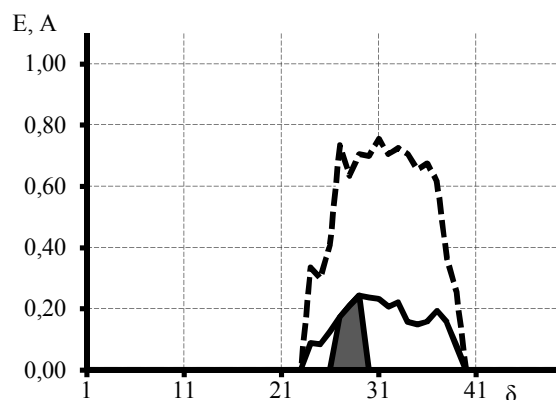


Рисунок 2 - Залежність усередненого КФЕ (6) і точності класифікації пікселів від параметра поля контрольних допусків на ознаки розпізнавання

Аналіз рис. 2 показує, що оптимальне значення поля контрольних допусків при сегментації області уражень становить $\delta^* = 29$ при значенні усередненого нормованого критерію (6) $\bar{E}^* = 0,242$.

На рисунку 3 показано залежність усередненого нормованого критерію (6) та точності класифікації пікселів від кількості базових класифікаторів, що беруть участь у паралельній композиції. При цьому випадкові вибірки реалізацій для кожного з класів будь-якого базового класифікатора становить $n = 100$.




Рисунок 3 - Залежність усередненого КФЕ (6) та точності класифікації від кількості класифікаторів при сегментації

Аналіз рис. 3 показує, що при збільшенні кількості базових класифікаторів, які беруть участь у паралельній композиції рішень, точність сегментації всіх доступних зображень спочатку має тенденцію до підвищення, але при кількості класифікаторів більшій ніж 6 точність істотно не змінюється. При цьому середнє значення КФЕ (6) навчання базових класифікаторів коливається в діапазоні $0,191 \dots 0,293$.




Рисунок 4 - Залежність середнього значення КФЕ (б) та точності класифікації від кількості класифікаторів під час оцінювання ступеня ураження нирки

На рисунку 4 показано залежність усередненого нормованого критерію (б) та точності розпізнавання рівня ураження паренхіми від кількості базових класифікаторів, що беруть участь у паралельній композиції вирішальних правил.

Аналіз рис. 4 показує, що точність оцінювання ступеню ураження паренхіми спочатку збільшується, а за кількості класифікаторів більшої ніж 9 точність істотно не змінюється. При цьому середнє значення КФЕ (б) навчання базових класифікаторів коливається в діапазоні 0,202...0,301.

На рисунку 5 на прикладі одного зображення лівої нирки проілюстровано етап експертної розмітки зображення та етапи автоматичної сегментації і виділення контурів уражень за оптимальних параметрів функціонування діагностичної системи.

Аналіз рис. 5 показує, що за оптимальних параметрів функціонування діагностичної системи результат сегментації дещо відрізняється від експертної розмітки, проте аналіз рис. 4 показує, що неточність сегментації не погіршила точності медичного висновку щодо ступеня ураження нирки.

Таким чином, у результаті машинного навчання композиції базових інформаційно-екстремальних класифікаторів вдалося синтезувати безпомилкові за навчальною матрицею вирішальні правила в умовах перетину в просторі ознак та незбалансованості класів розпізнавання.




Рисунок 5 - Результати етапів обробки зображення після фільтрації: а – експертна розмітка; б – автоматична сегментація; в – виділення контурів

ВИСНОВКИ

Отже, розроблений інформаційно-екстремальний алгоритм сегментації сцинтиграм статичного радіонуклідного дослідження дозволяє реалізувати автоматичне виділення зон інтересу за оптимальними в інформаційному сенсі вирішальними правилами. При цьому вдалося синтезувати безпомилкові за навчальною матрицею вирішальні правила для класифікації ступеня ураження паренхіми нирок в умовах обмежених за обсягом навчальних вибірок та перетину класів у просторі ознак.

Результати фізичного моделювання підтверджують високу ефективність одержаних вирішальних правил у режимах сегментації та класифікації медичних зображень. Практична цінність одержаних результатів для комп'ютеризованої медицини полягає у формуванні сучасної науково-методологічної основи проектування здатних навчатися діагностичних систем для статичного обстеження на гамма-камері.

Intelligent Diagnostic System For Static Radionuclide Examination

A. S. Rizhova¹⁾, V. V. Moskalenko²⁾

^{1), 2)} *Sumy State University, 2, Rimsky Korsakov Str., 40007, Sumy, Ukraine*

The article presents the method of an informational synthesis of decision rules for radionuclide diagnostic system of static examination of the human on gamma camera in case of unbalanced training dataset. The making of input mathematical description for intelligent radionuclide diagnostic system is considered. The algorithms for segmentation and classification scintigraphy images based on information-extreme machine learning are developed. The algorithms are based on adaptive binary coding of feature vectors and optimization of geometrical parameters of feature space partition into classes with containers which build into a radial basis of binary Hamming space to maximize the information ability of system intended to radionuclide diagnostics. The modified S. Kulback's information criterion for estimate efficiency of diagnostic system is expressed in terms of positive and negative predictive value. The physical modeling of proposed algorithms is implemented by the example of bootstrap aggregating information-extreme classifiers intended to estimation of level of kidney lesion.

Keywords: image segmentation, classification, machine learning, information criterion, optimization, feature set, radionuclide diagnostics, gamma camera.

Интеллектуальная система диагностики для радионуклидного статического обследования

А. С. Рыжова¹⁾, В. В. Москаленко²⁾

^{1), 2)} *Сумский государственный университет, ул. Римского-Корсакова, 2, Сумы, Украина, 40007*

Предлагается метод информационного синтеза решающих правил диагностической системы для радионуклидного статического обследования органов человека на гамма-камере в условиях несбалансированного объема обучающих выборок классов распознавания. Рассматривается формирование входного математического описания диагностической системы. Разработаны алгоритмы сегментации и классификации скintiграфических изображений на основе информационно-экстремального машинного обучения. Разработанные алгоритмы основываются на адаптивном двоичном кодировании значений признаков распознавания и оптимизации геометрических параметров разбиения пространства признаков на классы эквивалентности, контейнеры которых восстанавливаются в радиальном базисе бинарного пространства Хэмминга, в процессе максимизации информационной способности диагностической системы. В качестве критерия функциональной эффективности диагностической системы использовано модификацию информационного критерия по С. Кульбаку в виде функционала от первой и второй достоверностей решений, принимаемых в рабочем режиме системы. В качестве примера реализации предложенных алгоритмов рассматривается параллельная композиция информационно-экстремальных классификаторов для оценки уровня поражения паренхимы почек инфекционными заболеваниями.

Ключевые слова: сегментация изображений, классификация, машинное обучение, информационный критерий, оптимизация, словарь признаков, радионуклидная диагностика, гамма-камера.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Гектин А. В. Сцинтилляционные материалы. Получение, свойства, применение / А. В. Гектин, А. В. Демин, В. Ю. Педаш. – Харьков : Институт монокристаллов, 2007. – 416 с.
2. Нікілов М. О. Комп'ютерний аналіз кількості функціонуючої паренхіми нирок за даними нефросцинтиграфії з ^{99m}Tc-ДМСО / М. О. Нікілов, Д. О. Супрунюк, А. Л. Каміньська та ін. // Український радіологічний журнал. – 2014. – Т. 22, № 3. – С. 98 - 101.
3. Mohamed Y. Enhancement of Nuclear Medicine Images using Filtering Technique / Y. Mohamed, Y. Abdallah, E. Wagiallah // International Journal of Science and Research. – 2014. – Vol. 3, Issue 8. – P. 916 - 921.
4. Landgren M. An Automated System for Analysis of Renal Scintigraphy Images / M. Landgren, K. Sjostrand, L. Edenbrandt // European Journal of Nuclear Medicine and Molecular Imaging. – 2011. – P. 489 - 500.
5. Gonzalez F. A. Biomedical Image Analysis and Machine Learning Technologies: Applications and Techniques / F. A. Gonzalez, E. Romero. – Hershey, PA, USA : IGI, 2009. – 390 p.
6. Moskalenko V. V. Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes / A.S. Dovbysh, N.N. Budnyk, V.V. Moskalenko // Journal of automation and information sciences. – 2012. – Vol. 44, I.10. – P. 35-44.
7. Shrestha S. Image denoising using new adaptive based median filter / S. Shrestha // Signal & Image Processing : An International Journal. – 2014. – Vol. 5, No 4. – P. 1-13.
8. Zhou P. An Improved Adaptive Threshold Canny Edge Detection Algorithm / P. Zhou, W. Ye, Y. Xia, Q. Wang // Journal of Computational Information Systems. – 2011. – P. 1516-1523.
9. Suzuki S. Topological Structural Analysis of Digitized Binary Images by Border Following / S. Suzuki, K. Abe // Computer vision, graphics, and image processing. – 1985. – N 30. – P. 32-46.
10. Сайт бібліотеки машинного зору [Електронний ресурс].

– Режим доступу : <http://opencv.org/>.

11. Москаленко В. В. Інформаційно-екстремальне машинне навчання за незбалансованими даними великого розміру / В. В. Москаленко // Біоніка інтелекту. – 2015. – № 1 (84). – С. 34-39.

12. Yap B. W. An Application of Oversampling, Undersampling, Bagging and Boosting in Handling

REFERENCES

1. Gektin A. V., Demin A. V., & Pedash V. Ju. (2007). Scintillacionnye materialy. Poluchenie, svojstva, primenenie [Scintillation materials. Obtaining, properties and application]. Har'kov: Institut monokristallov. [in Russian].
2. Nikolov M. O., Suprunjuk D. O., Kamins'ka A. L., Chizhevs'kij V. B., & Makarenko A.V. (2014). Komp'juternij analiz kil'kosti funkcionujuchoi parenhimi nirok za danimi nefroscintigracii z 99mTc-DMSO [Computer analysis of the number of functioning renal parenchyma according to the neuroscientifically data with 99mTc-DMSO]. Ukrains'kij radiologichnij zhurnal – Ukrainian Journal of Radiology, 22, 3, 98-101. [in Ukraine].
3. Mohamed Y., Abdallah Y., Wagiallah E. (2014). Enhancement of Nuclear Medicine Images using Filtering Technique. International Journal of Science and Research, 3, 8, 916-921.
4. Landgren M., Sjostrand K., Edenbrandt L. (2011). An Automated System for Analysis of Renal Scintigraphy Images. European Journal of Nuclear Medicine and Molecular Imaging, 489–500.
5. Gonzalez F. A., & Romero E. (2009). Biomedical Image Analysis and Machine Learning Technologies: Applications and Techniques. IGI Global.
6. Moskalenko V. V., Dovbysh A. S., & Budnyk N. N. (2012). Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes. Journal of

Imbalanced Datasets / B. W. Yap, K. A. Rani at al. // Proceedings of the First International Conference on Advanced Data and Information Engineering. Lecture Notes in Electrical Engineering. – 2014. – Vol. 285. – Singapore : Springer Science. – P. 13-22.

automation and information sciences, 44, 35-44.

7. Shrestha S. (2014). Image denoising using new adaptive based median filter. Signal & Image Processing: An International Journal, 5, 4, 1-13.

8. Zhou P., Ye W., Xia Y., & Wang Q. (2011). An Improved Adaptive Threshold Canny Edge Detection Algorithm. Journal of Computational Information Systems, 75, 1516-1523.

9. Suzuki S., Abe K. (1985). Topological Structural Analysis of Digitized Binary Images by Border Following. Computer vision, graphics, and image processing, 30,1, 32-46.

10. Sait byblyoteki mashynogo zoru opencv.org. Retrieved from <http://opencv.org/>. [in Ukraine].

11. Moskalenko V. V. (2015) Informacijno-ekstremal'ne mashinne navchannja za nezbilansovanymi danimi velikogo rozmiru [Information-extreme machine learning for unbalanced big data]. Bionika intelektu – Bionics of Intelligence, 1 (84), 34-39. [in Ukraine].

12. Yap B. W., Rani K. A., Rahman H. A. A., Fong S., Khairudin Z., & Abdullah N. N. (2014). An Application of Oversampling, Undersampling, Bagging and Boosting in Handling Imbalanced Datasets. Proceedings of the First International Conference on Advanced Data and Information Engineering: Lecture Notes in Electrical Engineering. (pp. 13-22).