

## АВТОМАТИЧНА КЛЪСТЕРИЗАЦИЯ НА МНОГОСПЕКТРАЛНИ ИЗОБРАЖЕНИЯ ПОСРЕДСТВОМ РЕКУРЕНТНИ НЕВРОННИ МРЕЖИ

Петя Копринкова-Христова<sup>1</sup>, Кирил Алексиев<sup>1</sup>,  
Деница Борисова<sup>2</sup>, Георги Желев<sup>2</sup>, Валентин Атанасов<sup>2</sup>

<sup>1</sup>Институт по информационни и комуникационни технологии – Българска академия на науките

<sup>2</sup>Институт за космически изследвания и технологии – Българска академия на науките

e-mail: pkoprinkova@bas.bg; dborisova@stil.bas.bg

**Ключови думи:** многоспектрални изображения, клъстеризация, рекурентни невронни мрежи, невронни мрежи тип „ехо“, размит метод на C-средните (subtractive clustering)

**Резюме:** В работата е представено едно приложение на разработен наскоро алгоритъм за автоматична клъстеризация на многоспектрални изображения. Подходът се състои в „проектиране“ на многомерното изображение в двумерно пространство. За целта се използват т. нар. невронни мрежи тип „ехо“ (Echo state networks), наричани за кратко ESN, които са рекурентни невронни мрежи принадлежащи на фамилията „резервоарни“ мрежи. ESN мрежите се състоят от генериран на случаен принцип „резервоар“ от неврони със съответните връзки помежду им и сигмоидална нелинейност на изходите им (най-често хиперболичен тангенс). За адаптация на равновесните състояния на резервоара към многомерните входни данни се използва т. нар. процедура за „вътрешна пластичност“ (Intrinsic Plasticity или кратко IP), чиято първоначална цел е била максимизиране на ентропията на изхода на резервоара. За целите на клъстеризацията ние разглеждаме всички възможни комбинации между всеки два неврона и по-специално на получените след адаптацията на резервоара равновесни състояния на невроните, като ги разглеждаме като двумерни проекции на многомерното изображение. Към така получените проекции се прилага методът наречен „subtractive clustering“, който позволява да се определят автоматично броя и центровете на клъстерите във всяка проекция. Изследвали сме два подхода за избор на най-подходящите двумерни проекции измежду възможните комбинации. Първият подход се основава на определяне на двумерната плътност на разпределение на всяка проекция, броя максимуми в двумерното разпределение и избор на проекциите с най-голям брой максимуми. Вторият подход определя броя на клъстерите във всяка проекция, след което се избират проекциите с максимален брой клъстери. Разработените алгоритми са приложени към многоспектрални изображения на част от територията на България (планински терен в Родопите), получени от Landsat 7 / ETM+. Полученото от алгоритъма разделяне на терена на клъстери е сравнено с данните от регионалната класификация на същия терен.

## RECURRENT NEURAL NETWORKS FOR AUTOMATIC CLUSTERING OF MULTISPECTRAL SATELLITE IMAGES

Petya Koprinkova-Hristova<sup>1</sup>, Kiril Alexiev<sup>1</sup>, Denitza Borisova<sup>2</sup>, Georgi Jeleu<sup>2</sup>, Valentin Atanasov<sup>2</sup>

<sup>2</sup>Space Research and Technology Institute – Bulgarian Academy of Sciences

<sup>1</sup>Institute of Information and Communication Technologies – Bulgarian Academy of Sciences

e-mail: pkoprinkova@bas.bg; dborisova@stil.bas.bg

**Keywords:** multispectral satellite image, data clustering, recurrent neural network, Echo state network, fuzzy C-means

**Abstract:** In the present work, we applied a recently developed procedure for multidimensional data clustering to multispectral satellite images. The core of our approach lays in projection of the multidimensional image to a two dimensional space. For this purpose we used extensively investigated family of recurrent artificial neural networks (RNN) called “Echo state network” (ESN). ESN incorporates a randomly generated recurrent reservoir with sigmoid nonlinearities of neurons outputs. The procedure called Intrinsic Plasticity (IP) that is aimed at reservoir output entropy maximization was applied for adapting of reservoir steady states to the multidimensional input data. Next, we consider all possible combinations between steady states of each two

neurons in the reservoir as two-dimensional projections of the original multidimensional data. These low dimensional projections were subjected to subtractive clustering in order to determine number and position of data clusters. Two approaches to choose a proper projection among the all-possible combinations between neurons were investigated. The first one is based on the calculation of two-dimensional density distributions of each projection, determination of number of their local maxima and choice of the projections with biggest number of these maxima. The second one applies clustering to all projections and chooses those with maximum number of clusters. Multispectral data from Landsat 7 Enhanced Thematic Mapper Plus (ETM+) instrument are used in this work. The obtained number and position of clusters of a multi-spectral image of a mountain region in Bulgaria is compared with the regional landscape classification.

## Въведение

Независимо от многобройните разработки [1], клъстеризацията на многомерни данни е все още предизвикателство. Сред множеството подходи за решаването ѝ успешно приложение намират интелигентните методи с използване на размита логика и невронни мрежи. В частност, равновесните състояния на рекурентните невронни мрежи (PHM) [2-4] са използвани с успех за класификация на данни. За целта PHM се обучават несупервайзорно, минимизирайки зададена функция на енергията на изхода на невроните с цел настройване на теглата на връзките в мрежата спрямо структурата на данните.

Една сравнително нова и широко изследвана група PHM, обобщена под името „резервоарни изчисления“ [5], е създадена първоначално с цел повишаване скоростта на супервайзорното обучение на PHM. Една представителна за групата структура, наречена невронна мрежа тип „ехо“ (ESN) [6], се състои от рекурентен резервоар от неврони със сигмоидална нелинейност на изходите им. Макар, че като правило връзките в резервоара се генерират на случаен принцип, съществуват редица методи за тяхната настройка спрямо данните, с които ще работи невронната мрежа. Повечето такива методи целят максимизация на ентропията на изхода на резервоара [7, 8]. Тяхната мотивация е свързана с известните биологични механизми на промяна на възбудимостта на невроните в съответствие с разпределението на входните стимули [9]. За целта се добавя допълнителен параметър наречен праг (bias), който „премества“ работната точка на резервоара в желаната посока. В [9] е предложен градиентен алгоритъм, наричан „Подобряване на вътрешната пластичност“ (Intrinsic plasticity, или IP), който настройва стойността на праговете параметри, както и на допълнително въведения параметър на „усилване“ (gain) за всеки неврон. Цел на този алгоритъм е постигане на желано разпределение на изхода на резервоара. В [10] е експериментално доказано, че един страничен ефект на този алгоритъм е подобряване устойчивостта на резервоара дори и при генерирани първоначално неустойчиви резервоари. По време на изследванията как точно IP алгоритъма влияе на устойчивостта беше наблюдаван и друг интересен ефект: равновесните състояния на невроните бяха не само премествани, но и концентрирани в няколко различни области на многомерното пространство. Това постави въпроса възможно ли е да се използва този ефект за клъстеризационни цели? Подобна, но не идентична идея вече е използвана в [11] за извличане на „скритите“ характеристики на изображения, които се използват в последствие като „черти“ (features) подавани на входа на слоеста невронна мрежа използвана за класификацията им.

В [12] сме използвали тази особеност на резервоара, но от друга гледна точка: възможните комбинации между равновесните състояния на всеки два неврона в резервоара, получени в следствие на представянето на многомерните входни данни на ESN, бяха разглеждани като двумерни проекции на многомерния входен вектор, които могат да бъдат използвани в последствие за целите на клъстеризация в двумерното пространство. Беше показано, че освен подобрената устойчивост, настроеност с IP алгоритъм резервоар притежава и по-добри клъстеризационни свойства, в следствие на което беше разработена клъстеризационна процедура за многомерни данни. С нарастването на размера на резервоара обаче, броят на възможните двумерни проекции се увеличава драстично. Поради това беше необходимо да се търси подходяща процедура за избор на най-подходящата(те) двумерни проекции сред множеството възможни. Първоначалната идея [12] беше да се използва плътността на разпределение на изхода на всеки неврон и избор на проекция между невроните с най-голям брой максимуми на това разпределение. Тази процедура обаче изисква подходящ избор на широчината на използваните за целта kernel функции. В по-нататъшните изследвания в [13] са използвани двумерните плътностни разпределения на всяка двумерна проекция и е използвана процедурата от [14], която определя автоматично ширината на kernel функциите. Тази процедура е приложена за клъстеризацията на многоспектралните спътникови изображения. Резултатите показаха, че с нея се избира еднозначно една от възможните двумерни проекции на многомерния входен вектор.

Въпреки това въпросът за избор на подходящата двумерна проекция все още не е еднозначно решен, поради което тук са сравнени двата алгоритъма от [12] и [13], като са показани предимствата и недостатъците им. Сравнени са и резултатите, получени с различен брой неврони в резервоара на ESN, като е показано, че колкото по-голям е той, толкова повече отделни класове могат да бъдат разграничени. За целта на изследването са използвани многоспектрални изображения получени от спътника Landsat 7, сензор Enhanced Thematic Mapper Plus (ETM+). Получените резултати от клъстеризацията на изображения от планински регион в Родопите са сравнени с регионалната класификация на терена и с негови снимки. Наблюдава се скриване или грешна класификация на част от обектите в региона в резултат на сенките в изображението, но с намаляването на броя разграничени клъстери намалява и частта от изображението с грешно класифицирани обекти. При по-голям брой клъстери част от грешно класифицираните преди обекти попадат в нов клъстер, което също води до намаляване на грешно класифицираните обекти. При по-малък брой клъстери наклоните се очертават по-ясно, докато при разграничаване на повече клъстери се отчитат повече детайли от земното покритие.


## 1. Алгоритъм за клъстеризация

### 1.1 ESN и IP подобрене на резервоара

Фигура 1 представя структурата на ESN резервоар. Неговата динамика се описва както следва [6]:

$$(1) \quad r(k) = f^{res}(W^{in}u(k) + W^{res}r(k-1))$$

където  $u(k)$  е входен вектор на резервоара с размерност  $n_u$ ,  $r(k)$  е векторът на състоянието на невроните в резервоара с размерност  $n_r$ ;  $W^{in}$  и  $W^{res}$  са  $n_r \times n_u$  и  $n_r \times n_r$  матрици, които се генерират на случаен принцип. Невроните в резервоара имат сигмоидална функция на изхода  $f^{res}$ , която най-често е хиперболичен тангенс.



Фиг. 1. Структура на невронна мрежа тип „ехо“ (ESN)

В [8, 9] са въведени два нови параметъра на резервоара: усилване (gain)  $a$  и праг (bias)  $b$  (и двата с размерност  $n_r$ ). Така изходът на резервоара се модифицира, както следва:

$$(2) \quad r(k) = f^{res}(diag(a)W^{in}u(k) + diag(a)W^{res}r(k-1) + b)$$

Двата нововъведени параметъра са обект на процедура за настройване [8, 9], наречена IP подобрене. Тя представлява градиентен алгоритъм, който минимизира дадена мярка за разликата между фактическото  $p(r)$  и желаното  $p_d(r)$  вероятностно разпределение на изхода на резервоара  $r$ . Тази мярка е разстоянието на Kullback-Leibler ( $D_{KL}$ ) между двете разпределения, както следва:

$$(3) \quad D_{KL}(p(r), p_d(r)) = \int p(r) \log \left( \frac{p(r)}{p_d(r)} \right)$$

Според [9] подходящото целево разпределение е това, което максимизира информацията на изхода на невроните. Доказано е, че при нелинейна функция на изхода на резервоара хиперболичен тангенс е желателно целевото разпределение да бъде Гау сово.

Според уравнение (2) равновесното състояние на резервоара  $r_e$  при константен входен вектор  $u_c$  е:

$$(4) \quad r_e = \tanh\left(\text{diag}(a)W^{in}u_c + \text{diag}(a)W^{res}r_e + b\right)$$

Тъй като  $W^{in}=\text{const.}$ , първият член в скобите също е константен ( $u_c = \text{const.}$ ). Следователно уравнение (4) може да се преобразува както следва:

$$(5) \quad r_e = \tanh\left(\text{diag}(a)W^{res}r_e + b_{u_c}\right), \quad b_{u_c} = \text{diag}(a)W^{in}u_c + b$$

Следователно равновесното състояние ще бъде различно за различните входни вектори. Освен това, колкото по-близки са входните вектори във входното пространство, толкова по-близки ще са и съответстващите им равновесни състояния - факт, който може да се използва за целите на клъстеризацията.

## 1.2 Процедура за клъстеризация

Получените в резултат на IP обучението равновесни състояния (5) се използват за генериране на множество двумерни проекции на оригиналните многомерни входни данни, както следва [12]:

- Генерира се ESN резервоар със случайни връзки и се обучава с IP алгоритъма представяйки на входа му всички входни многомерни вектори.
- Определят се равновесните състояния на настроенния резервоар за всеки входен вектор от многомерните данни.
- Всички равновесни състояния се мащабират в интервала [-1, +1].
- Прилага се процедурата за subtractive клъстеризация [15] към избрани двумерни проекции, за да се определи автоматично положението и броя на клъстерните центрове. Известно е, че процедурата за subtractive клъстеризация е най-добрият избор при неизвестен брой на търсените клъстери [16].

Колкото по-голям е броя неврони в резервоара, толкова по-голям е броят на възможните двумерни проекции. Следователно е необходимо да се изберат малко от тях, за да се определи структурата на многомерните данни. Изследвани са следните два подхода:

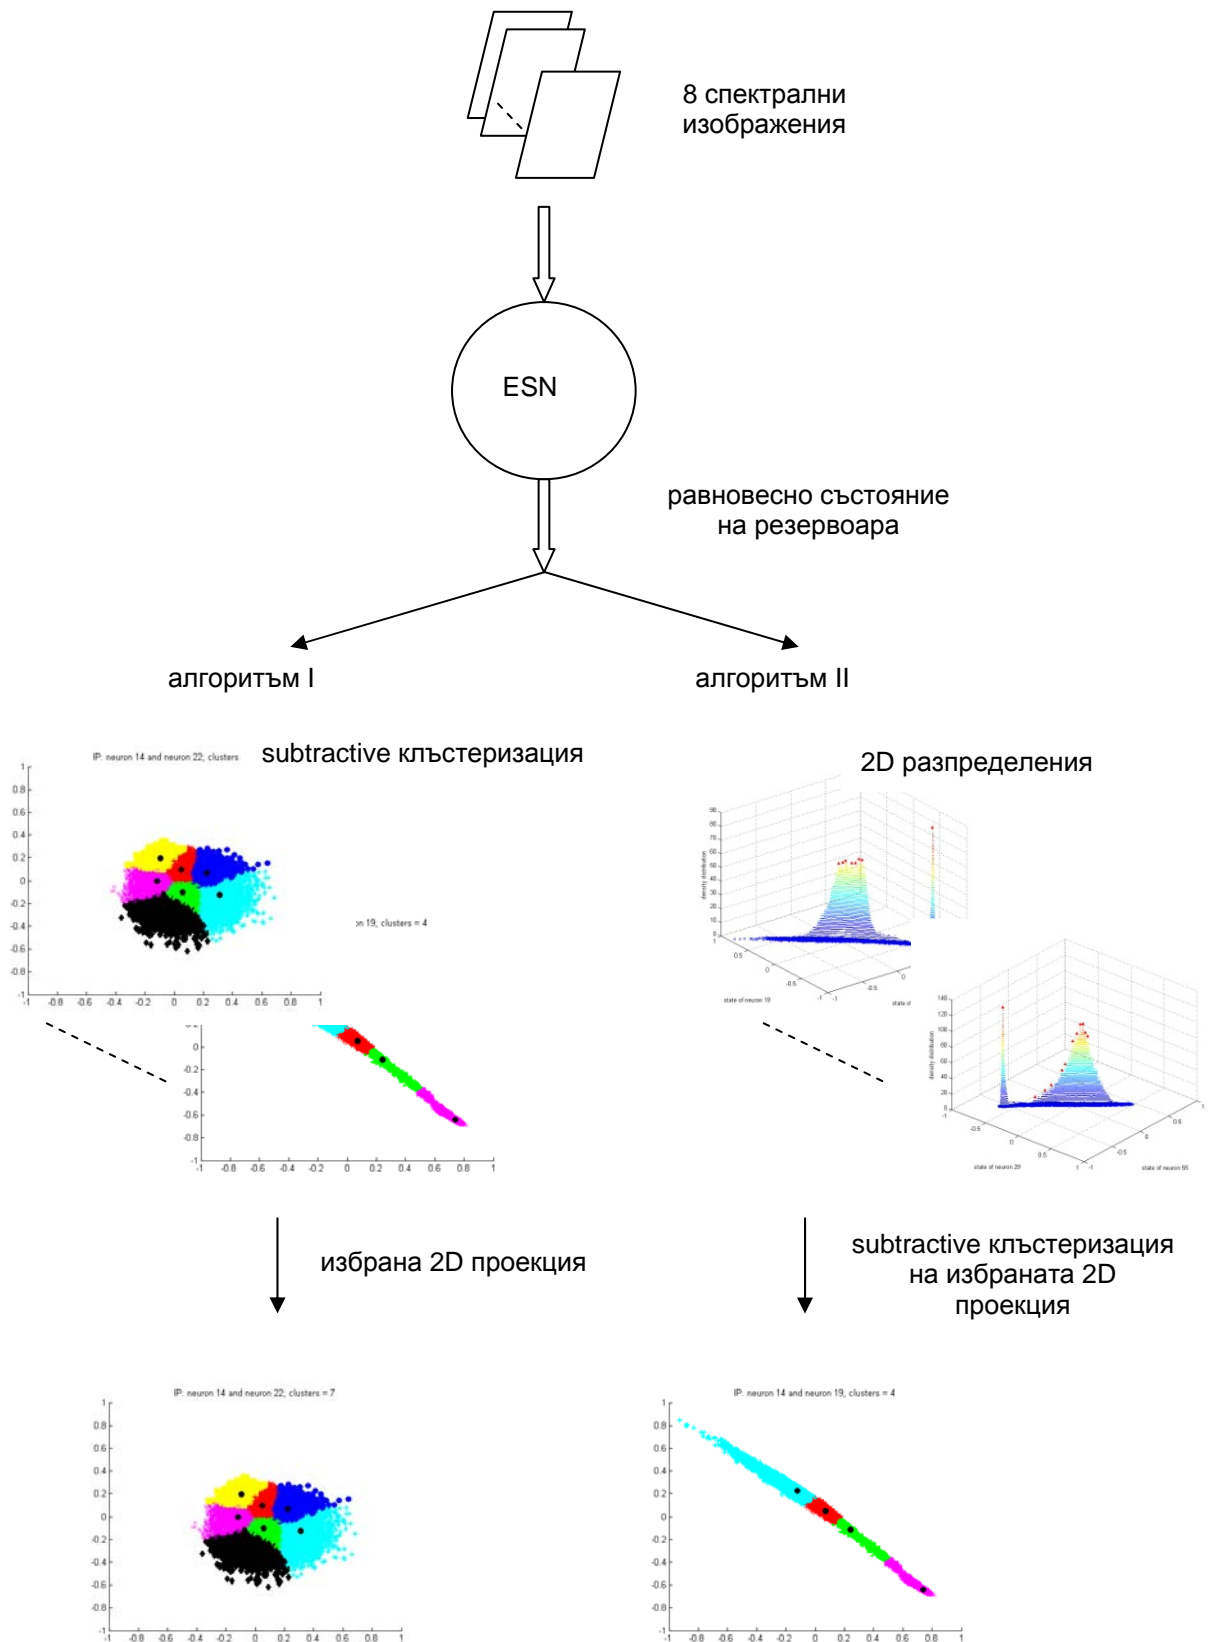
I. Прилагане на процедурата subtractive клъстеризация към всички възможни двумерни проекции и избор на тази/тези, които имат максимален брой клъстери.

Този подход изисква много време и изчислителни ресурси, понеже отчита всички възможни двумерни проекции, но за сметка на това позволява да се избере проекцията с максимален брой клъстери, която се предполага, че прави най-финото разделяне на многомерните данни.

II. Прилагане на процедурата subtractive клъстеризация само към избрани двумерни проекции на базата на двумерните плътности на разпределението на всички проекции, както следва:

- Определят се двумерните плътности на разпределението на всички възможни двумерни проекции използвайки алгоритъма описан в [14] и кода на Матлаб, който го реализира от [17];
- Определят се локалните максимуми на всяко разпределение използвайки кода на Матлаб от [18];
- За клъстеризация се избират проекциите с най-голям брой локални максимуми;

Този подход изисква по-малко време и изчислителни ресурси, но има повече стъпки. Това се дължи на факта, че най-бавната стъпка и в двата алгоритъма е процедурата за subtractive клъстеризация. Но тази процедура не гарантира избор на проекция с максимален брой клъстери, както се вижда и от нашия опит. Тъй като няма правило какъв брой клъстери е реалистичен за



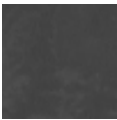
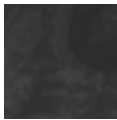
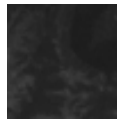
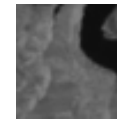
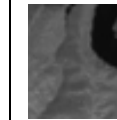
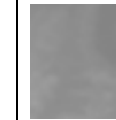

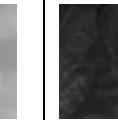
Фиг. 2. Алгоритми за клъстеризация

даден набор многомерни данни, за някои приложения този подход може да постигне по-добър резултат с по-малко изчисления. Фигура 2 представя двата алгоритъма в паралел.

### 1.3 Многоспектрални изображения

Чрез ресурсния спътник Landsat, на чиято платформа са разположени серия сензори със средна пространствена разделителна способност, е събрана най-дългата непрекъсната колекция от данни от дистанционни изследвания на земната повърхност. Близко четири десетилетия се осигурява уникален ресурс за тези, които работят в селското стопанство, геологията, горското стопанство, регионалното планиране, образованието, картографирането, глобалните изследвания на климата и др. Изображенията от Landsat също така са безценни за реакцията при спешни случаи и помощ при бедствия. Тъй като е съвместна инициатива между геоложката служба на САЩ (USGS) и националната аерокосмическа администрация (NASA), проектът Landsat и данните, които събира, подкрепят правителството, търговски, промишлени, граждански, военни и образователни общности в Съединените щати и по света. В тази работа се използват многоспектрални данни от Landsat 7-сензор "Подобрен Тематичен Картограф Плюс" (ETM+). Изображенията от Landsat ETM+ се състоят от осем спектрални канала с пространствена разделителна способност от 30 м за всички канали от 1 до 7. За всички канали могат да се регистрират едно от двете нива на усилване (високо или ниско) с цел подобряване на радиометричната чувствителност и на динамичния диапазон, докато за канал 6 се регистрират едновременно и двете нива за всички сцени. Приблизителният размер на една сцена е 170 км в посока север-юг на 183 km в посока изток-запад. Всички стандартни данни са обработени със системата Level 1 Product Generation System (LPGS) и имат следните параметри: ниво 1 T (L1T) – въведена корекция за релеф; формат GeoTIFF; преработен спектрален куб чрез Cubic Convolution (CC); 16-битови стойности на пиксела. В Таблица 1 се представени характеристиките на сензора ETM+, разположен на борда на спътника Landsat 7, за всички използвани спектрални канали и съответните спектрални изображения.

Табл. 1. Характеристики на спътника Landsat 7 ETM+ и съответните спектрални изображения

Канал 1 (син) 0.45- 0.52 $\mu\text{m}$	Канал 2 (зелен) 0.52- 0.60 $\mu\text{m}$	Канал 3 (червен) 0.63 - 0.69 $\mu\text{m}$	Канал 4 (близък инфра- червен) 0.76- 0.90 $\mu\text{m}$	Канал 5 (среден инфра- червен) 1.55- 1.75 $\mu\text{m}$	Канал 6 (ниско ниво) (топлине н) 10.40- 12.50 $\mu\text{m}$	Канал 6 (високо ниво) (топлинен) 10.40- 12.50 $\mu\text{m}$	Канал 7 (среден инфра- червен) 2.09- 2.35 $\mu\text{m}$
							

## 2. Резултати и дискусия

### 2.1 Резултати от клъстеризацията

Обучени са две неврони мрежи тип „ехо“ с различен размер на резервоара – 20 и 100 неврона – използвайки многоспектралните спътникови изображения, описани в предходната секция. Размерността на входния вектор на ESN е  $n_U=8$  съобразно броя на спектралните изображения от Таблица 1. Всяко изображение е с размерност 50x50 пиксела. Така многомерният набор данни съдържа 2500 входни вектора с размерност  $n_U$  всеки.

Таблица 2 обещава избраните двумерни проекции на нашето многоспектрално изображение от Таблица 1 с използването на двата описани алгоритъма. Както се вижда от таблицата, алгоритъм I избира проекции с по-голям брой клъстери в сравнение с алгоритъм II. Но докато алгоритъм II избира само една проекция от всички възможни, алгоритъм I ни дава четири възможности в случая с по-големия резервоар. За сравнение сме приложили алгоритъма за subtractive клъстеризация [18] към оригиналния набор от 8 спектрални изображения, т.е. към 8-мерния набор данни. Получените като брой и позиции клъстери са показани на последния ред в

Табл. 2. Получени класификации на терена от многоспектралните изображения в сравнение с ортофото картата на терена от България [22] и класификацията на терена според CORINE [23]


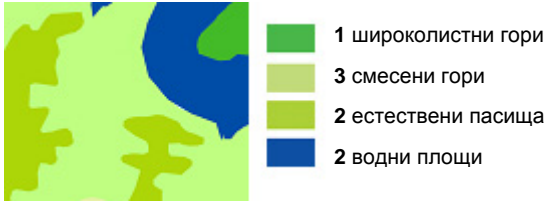
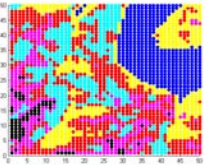
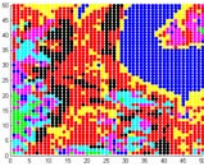
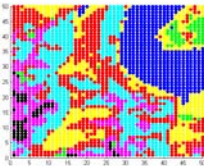


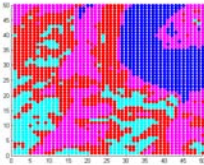
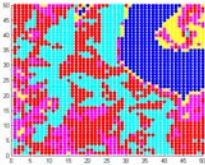
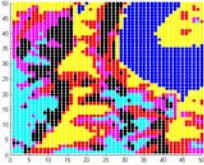
<b>Ортофото карта 2010</b>		<b>CORINE 2000</b>	
		 <ul style="list-style-type: none"> <li><span style="display: inline-block; width: 15px; height: 15px; background-color: #4CAF50; margin-right: 5px;"></span> 1 широколистни гори</li> <li><span style="display: inline-block; width: 15px; height: 15px; background-color: #C8E6C9; margin-right: 5px;"></span> 3 смесени гори</li> <li><span style="display: inline-block; width: 15px; height: 15px; background-color: #FFF9C4; margin-right: 5px;"></span> 2 естествени пасища</li> <li><span style="display: inline-block; width: 15px; height: 15px; background-color: #2196F3; margin-right: 5px;"></span> 2 водни площи</li> </ul>	
<b>Алгоритъм I</b>		<b>Алгоритъм II</b>	
<b>ESN с 20 неврона 6 клъстера</b>	<b>ESN със 100 неврона 7 клъстера</b>	<b>ESN с 20 неврона 4 клъстера</b>	<b>ESN със 100 неврона 5 клъстера</b>
	   		
<b>Subtractive клъстеризация на 8D оригиналните данни 6 клъстера</b>			
			

Таблица 2. Те са сравними с резултатите получени от алгоритъм I и ESN с по-малкия резервоар. При по-голям размер на резервоара се увеличава и броят на клъстерите. Следователно предварителната обработка на многомерните данни с рекурентната невронна

мрежа и генерирането на двумерните проекции ни позволява да получим по-детайлна клъстеризация на многомерните данни.

## 2.2 Сравнителни резултати

Верификацията на новопредложената процедура за клъстеризация с рекурентни невронни мрежи тип „ехо“ е направена посредством сравнения на получените резултати с наличните карти от географските информационни системи на Министерството на регионалното развитие и по-специално с класификацията на земното покритие при минимум отчетена площ 25 хектара. Численото сравнение на нашите резултати с картите от CORINE е невъзможно на практика поради различната разделителна способност на използваните изображения. Според картата на CORINE регионът се разделя на 4 клъстера (Таблица 2). Алгоритъм II с 20 неврона в резервоара на ESN дава също 4 клъстера, които са доста близки визуално до тези от CORINE. Това ни дава увереност, че нашият алгоритъм работи коректно.

Алгоритъм I при двата размера на резервоара - 20 и 100 неврона, както и алгоритъм II при резервоар от 100 неврона откриват по-голям брой клъстери. Поради това ние сравнихме тези резултати с ортофото картата на региона, която има по-високо пространствено разрешение от 0.5x0.5m. Въпреки, че е трудно да се свърже всеки от получените клъстери с различните типове земно покритие, ние предполагахме, че тази класификация е в състояние да различава повече и по-специфични детайли от многоспектралните изображения.

## 3. Заключение

Приложението на наскоро разработената процедура за клъстеризация на многомерни данни, която използва невронни мрежи тип „ехо“ и алгоритъма за subtractive клъстеризация, към многоспектралните изображения показва сравнително добра способност за класификация на терена в зависимост от земното покритие. По-нататъшно подобрене на резултатите може да бъде постигнато с подходящ избор само на част от каналите, които да се използват при клъстеризацията с цел да се откриват специфични типове земно покритие от спътниковите данни. В нашата бъдеща работа ние планираме да приложим спектрометрични измервания на терена и да сравним нашата класификация с предварително известната информация за наблюдаваните обекти. Алгоритмите, с които се откриват повече от четири клъстера (Таблица 2) биха могли да се използват за по-детайлна класификация на земното покритие в сравнение с тази на CORINE или биха могли да се използват за пето ниво на CORINE класификацията.

## Благодарности

Изследването в настоящата работа е проведено в рамките на договор ДФНИ – И01/8, 2012, между ИКИТ – БАН и Фонд “Научни изследвания”.

## Литература:

1. Jain, A.K., Murty, M.N. and Flynn, P.J., “Data Clustering: A Review,” ACM Computing Surveys, 31(3), 264-323 (1999).
2. Ackley, D.H., Hinton, G.E. and Sejnowski, T.J., “A learning algorithm for Boltzmann machines,” Cognitive Science, 9, 147-169 (1985).
3. Hinton, G.E. and Salakhutdinov, R., “Reducing the dimensionality of data with neural networks,” Science, 313(5786), 504-507 (2006).
4. Hopfield, J.J., “Neural networks and physical systems with emergent collective computational abilities,” Proc. of National Academy of Sciences USA, 79, 2554-2558 (1982).
5. Lukosevicius, M. and Jaeger, H., “Reservoir computing approaches to recurrent neural network training,” Computer Science Review, 3, 127-149 (2009).
6. Jaeger, H., “Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the “echo state network” approach,” GMD Report 159, German National Research Center for Information Technology (2002)
7. Ozturk, M., Xu, D. and Principe, J., “Analysis and design of Echo state networks,” Neural Computation, 19, 111-138 (2007).
8. Steil, J.J., “Online reservoir adaptation by intrinsic plasticity for back-propagation-decoloration and echo state learning,” Neural Networks, 20, 353-364 (2007).
9. Schrauwen, B., Wandermann, M., Verstraeten, D., Steil, J.J. and Stroobandt, D., “Improving reservoirs using intrinsic plasticity,” Neurocomputing, 71, 1159-1171 (2008).
10. Koprinkova-Hristova, P. and Palm, G., “ESN intrinsic plasticity versus reservoir stability,” Lecture Notes in Computer Science, 6791, 69-76 (2011).



11. Woodward, A. and Ikegami, T., "A reservoir computing approach to image classification using coupled echo state and back-propagation neural networks," Proc. of 26<sup>th</sup> Int. Conf. on Image and Vision Computing, Auckland, New Zealand, 543-458 (2011).
12. Koprinkova-Hristova, P. and Tontchev, N., "Echo state networks for multi-dimensional data clustering," Lecture Notes in Computer Science, 7552 LNCS (PART 1), 571-578, (2012).
13. Koprinkova-Hristova, P., Angelova, D., Borisova, D., Jelev, G., "Clustering of spectral images using Echo state networks," Proc. IEEE INISTA, ISBN: 978-1-4799-0661-1 (2013), DOI: 10.1109/INISTA2013.6577633.
14. Botev, Z.I., Grotowski, J.F. and Kroese, D.P., "Kernel density estimation via diffusion," The Annals of Statistics, 38(5), 2916–2957, (2010).
15. Eli Billauer's home page, <http://billauer.co.il/peakdet.html> (accessed 2013).
16. Hammouda, K., "A comparative study of data clustering techniques," SYDE 625: Tools of Intelligent Systems Design. Course Project, Aug. 2000.
17. Fast and accurate state-of-the-art bivariate kernel density estimator by Z. Botev, <http://www.mathworks.com/matlabcentral/fileexchange/17204-kernel-density-estimation> (updated 2009).
18. Yager, R. and D. Filev, "Generation of Fuzzy rules by mountain clustering," Journal of Intelligent & Fuzzy Systems, 2(3), 209-219, (1994).
19. Landsat Missions, <http://landsat.usgs.gov/> (accessed 2013).
20. U.S. Geological Survey (USGS) Global Visualization Viewer, <http://glovis.usgs.gov/> (accessed 2013).
21. USGS (EROS) Center, [http://eros.usgs.gov/#/Find\\_Data/Products\\_and\\_Data\\_Available/TM](http://eros.usgs.gov/#/Find_Data/Products_and_Data_Available/TM) (accessed 2013).
22. Ministry of Agriculture and Food, [http://www.mzh.government.bg/MZH/bg/ShortLinks/cross\\_compliance/Cifrovaortofotokarta.aspx](http://www.mzh.government.bg/MZH/bg/ShortLinks/cross_compliance/Cifrovaortofotokarta.aspx) (accessed 2013).
23. MRRB GIS System security division, [http://gis.mrrb.government.bg/pmapper/map\\_separate-legend.phtml?winsize=medium&language=bg&config=separate-legend](http://gis.mrrb.government.bg/pmapper/map_separate-legend.phtml?winsize=medium&language=bg&config=separate-legend) (accessed 2013).