

инж. Христо Стоянов Николов

**ТЕМА:** *“Приложение на нелинейни методи от теорията за разпознаване на образи в  
дистанционните изследвания на Земята”*

**АВТОРЕФЕРАТ**

на дисертация

за присъждане на образователната и научна степен “ДОКТОР”

инж. Христо Стоянов Николов

**АВТОРЕФЕРАТ**

на дисертация

*“Приложение на нелинейни методи от теорията за разпознаване на образи в  
дистанционните изследвания на Земята”*

За присъждане на образователната и научна степен  
“ДОКТОР”

Област на висше образование: 4. “Природни науки, математика и информатика”;  
професионално направление: 4.4 “Науки за Земята”; научна специалност:  
“Дистанционни изследвания на Земята и планетите”

**Научни консултанти:**

1. доц. д-р Дойно Иванов Петков
2. проф. д-р Бойчо Великов Бойчев

**Научно жури:**

проф. д-р инж. Борислав Богданов Маринов  
проф. д-р инж. проф. д-р Явор Георгиев Чапанов  
проф. д-р инж. Юлин Николов Тепелиев  
доц. д-р инж. Дойно Иванов Петков  
доц. д-р Валентин Йонов Атанасов

---

София  
2018г.

Дисертацията включва 114 страници, 31 фигури и 24 таблици, оформени в 5 глави, приноси и публикации по дисертацията.

Библиографията обхваща 101 литературни източника. Номерата на фигурите, таблиците и графиките, съответстват на тези в дисертационния труд.

Дисертационният труд е обсъден и предложен за защита на разширен научен семинар на секция “Системи за дистанционни изследвания” на ИКИТ–БАН на 25.07.2018 г. с протокол от Разширен научен семинар на секцията.

Защитата на дисертацията ще се състои на ..... г. от ..... часа в зала ..... на ИКИТ (София, бул. “Акад. Г. Бончев, бл. 1), при открито заседание на Научното жури.

Материалите по защитата (дисертацията и рецензиите) са на разположение на интересуващите се в сградата на ИКИТ и на интернет страницата на института:  
[www.space.bas.bg](http://www.space.bas.bg).

Автор: Христо Николов  
Тираж: 10 броя  
София

## ВЪВЕДЕНИЕ

Дистанционните изследвания като метод за получаване на информация за изследвания обект се основават на данни от проведени измервания от определено разстояние без директно съприкосновение с обекта и попадат в категорията на неструктивните методи за получаване на данни за конкретен обект. При него измервателния апаратурен комплекс може да бъде с активен сензор, като в този случай към изследвания обект се изпраща енергия под формата на радиация и се регистрира върнатия към сензора сигнал, и пасивен сензор, който регистрира отразената слънчева или излъчената собствена радиация. Независимо от начина на получаване получените от апаратурния комплекс данни е необходимо те да бъдат подложени на предварителна и тематична обработки, и едва тогава да се получи тематична информация относно състоянието на изследваните обекти (Jensen,2015). В процеса на тематична обработка се прилагат два подхода – класификация без обучение и класификация с обучение, но и при двата се основават математическия апарат за разпознаване на образи. Важно е да се обърне внимание на факта, че поради естеството на данните от ДИ не следва да се очаква някой от подходите да има предимство, а по-скоро е необходимо познаването на проблема, който следва да се реши, да се използва подходящ набор от данни и не на последно място да се приложи повече от един метод за извличане на наличната в данните тематична информация. Точно такъв подход е избран и при реализацията на изследванията в тази дисертация.

### Глава 1. Предмет, обект, поставени цели и задачи в дисертацията

Процесът на сегментация и класификация на обекти от земната повърхност в многоканални спектрални изображения (МКСИ) следва да реши една класическа обратна задача – по данни получени от проверен и калибриран измервателен комплекс да се съди за параметрите на изследвания обект. Оттук беше формулира и ЦЕЛТА на това изследване – на базата на определен брой *измерими и статистически различни* признаци, в случая отчети за различни дължини на вълните на слънчевата радиация  $\lambda_i$  и/или комбинации от тях, да се извърши разделяне на обектите включени в набор многоканални спектрални данни (МКСД), прилагайки нелинейни математически методи за обработка на данни базирани на теорията за разпознаване на образи.

При спектрометричните методи на изследване за всеки елемент от изображението се формира многомерен вектор  $X$ , който го определя еднозначно на базата на измерените стойности за енергетична яркост на дължини на вълните  $\lambda_1 \dots \lambda_n$ . и/или техни трансформации (подмножества, отношения, линейни комбинации и др.), формирайки по този начин пространство на характеризиращите признаци (ХП). Приложените в тази дисертация методи за обработка на МКСД (математическа статистика, невронни мрежи (НМ) и метод на опорните вектори (МОВ)) попадат в групата методи за изграждане на модел на класификационна процедура с обучение за класификация на МКСД<sup>1</sup>.

Като *критерии* за оценка на качеството на моделите са използвани:

- точност при тематична класификация (напр. съотношение *коректно класифицирани/некоректно класифицирани обекти*);
- възможност на модела за обобщаване (generalization) т.е. изследване поведението му при необходимост да се класифицират данни невключени в обучаващото множество;
- тип и структура на модела описващ съответствието входни данни / търсен изход;
- влияние на размера на данните за обучаващата извадка необходима на етап „обучение на модел“;
- необходим изчислителен ресурс за обучение на модела;

---

<sup>1</sup> Този избор е обоснован и в (Thenkabail, 2016) стр. 236.

- сложност при програмна реализация на изградения модел и време за неговото обучение.

Приложените и доразвити в тази дисертация методи за тематична обработка на МКСД носят различни имена (identification, estimation, regression, classification, pattern recognition, function approximation, curve or surface fitting etc.), но в основата си тяхната същност е една – да се използва способността на изходните данни да се групират в по-големи или по-малки области от пространството на ХП, което се формира от самите тях. В тази дисертация е търсена и е обръщано специално внимание на наличната в данните способност да се самоорганизируют – проблематика, която е разработвана и се развива в секция „Системи за дистанционни изследвания“ на ИКИТ-БАН (Петков, 1991).

В изследваните случаи на практика е необходимо да се проследи поведението на конкретен реален обект от земната повърхност поставен в различни условия, използвайки емпирични данни и на тази основа да се изследва поведението му в нова и непозната ситуация (въздействаща среда; представяне на данни, които не са били включени в процеса на обучение и други). Тази необходимост се обуславя от следните предпоставки относно същността на данните, с които разполагаме – краен брой данни използвани на етап „обучение на модел“ (т.е. разполагаме с ограничена извадка); данните са зашумени и не са функция от всички възможни комбинации от входните параметри; физическата същност на получаваните данни не предполага тяхната повтаряемост. Последната особеност поставя на преден план способността на процедурата за тематична класификация след обучението ѝ да обобщава. Или казано с други думи да се проследи дали изградения модел реагира коректно с данни измерени за същия обект, но не включени в обучаващата извадка. Това означава, че тази процедура е необходимо да изгради не толкова модел на данните, а което е по-важно, модел на процесите, които ги създават.

Решаваните задачи в тази дисертация, свързани с тематичната класификация на обекти от земната повърхност посредством нелинейни модели, имат *теоретичен* и *практически* аспект. Теоретичният е свързан с прилагане на най-подходящия за конкретното изследване математически апарат и неговото модифициране с цел удовлетворяване на специфичните изисквания поставени към тематичната интерпретация на МКСД. Практическият аспект на работата е концентриран в следните направления: алгоритмизиране на теоретичните методи и разработки; програмната им реализация на език от високо ниво; интегриране на създадените програмни модули в софтуерен продукт за предварителна и тематична обработка на данни от дистанционни изследвания. Предимство на нелинейните методи при обработка на МКСД, и по-конкретно за създаване на тематични изображения на земната повърхност от тях, е че те позволяват разделяне на наличните в МКСД спектрални класове в пространството на ХП с криви описвани от нелинейни функции, което позволява постигане на по-висока точност на резултата след класификация.

Във връзка с изложеното по-горе към дисертацията са зададени:

*Предмет на изследването* – изследване на нелинейни методи и модели, реализиращи класификация с обучение при използване на МКСД получени от дистанционни изследвания на Земята от години 1999 и 2006, приложени при изучаване антропогенното влияние в Панагюрски руден район.

*Цели:*

- създаване на ефективна иновативна методика за подбор и предварителна обработка на МКСД;
- избор и тест на параметри на използваните модели за обработка на МКСД;
- разработка на система от критерии за оценяване на резултати, получени при използване на различни методи за класификация.

*Задачи на настоящата работа:*

- създаване и допълване на гео-база данни (ГБД) за Панагюрски руден район по налични свободно-достъпни векторни и растерни данни;

- създаване на методика за съвместно използване данни за отражателната способност на обекти върху земната повърхност от полеви системи, съпътстващи данни (напр. температура, влажност и др.), така и изчислени стойности за отражението на слънчевата радиация под формата на МКСИ, получени от апаратурни комплекси с аерокосмическо базиране;
- диахронно проследяване (времеви анализ) на промените за отделните класове от ГБД с цел отстраняване на нежелани при класификацията вариации в МСИ в рамките на един клас;
- теоретично обосноваване на прилагането на методи от разпознаване на образи (НМ и МОВ) с помощта на обучение на разпознаваща процедура (learning machine) за тематична обработка на данни, получени при експерименти от дистанционни изследвания;
- адаптиране теоретичните постижения от теорията на НМ и МОВ за нуждите на тематичната обектова класификация на данни от дистанционни изследвания;
- включване на допълнителни ХП (напр. цифров модел на терена) в процеса на класификация освен наличната спектрална информация;
- провеждане на паралелни изследвания включващи класификация със статистически методи, с модели с НМ и модели по МОВ, както и комбинации от тях, като за този случай ще се изследва поведението при различна структура на НМ и при използване на различни функционални ядра за МОВ;
- валидиране на получени формулировки и модели посредством пакети за математическа обработка;
- интегриране на получените модели на разпознаващи процедури, като външни модули в съществуващи програмни продукти за тематична обработка на данни за дистанционни изследвания.

## **Глава 2. Въведение в проблематиката на дистанционните изследвания**

### **2.1 Области на приложение и решавани задачи.**

В процеса на получаване на данни от ДИ на Земята най-често като измервани величини са отразената слънчева или излъчената собствена радиация и те се записват за последваща обработка под формата на спектрални трасови данни или изображения в един или повече спектрални канали (спектрални интервали)<sup>2</sup>. Тяхно основно предимство, е че предоставят възможност за дългосрочни, повтаряеми наблюдения на едни и същи площи от повърхност на Земята.

Приетата в тази дисертация дефиниция относно физическата същност на ДИ е, че “дистанционните изследвания са свързани с измерване на количествени параметри на електромагнитното поле излъчвано или отразено от природните и антропогенни образувания” (Мишев, 1981). Фактът, че всички природни и антропогенни образувания отразяват, поглъщат или излъчват падналата върху тях слънчева радиация по различен и характерен за тях начин е в основата на ДИ за наблюдение на Земята.

В множество изследвания е доказано, че между физикохимичните и/или биологични свойства на обектите и техните спектрални отражателни характеристики (СОХ)<sup>3</sup> съществува адекватност, която дава основание по спектрометрични данни да се съди за вида на природните образувания, както и различни техни параметри и/или състояния. Именно в тази пряка зависимост между спектралните отражателни характеристики на обектите и техните параметри се състои информативността на получаваните МКСД и възможността за използването им като характеризиращ признак, който гарантира разделимостта на обектите на базата на СОХ. (Kancheva, 2003)

<sup>2</sup> В рамките на тази дисертация тези два термина са използвани като синоними.

<sup>3</sup> Линия, която описва спектралното отражение или собственото излъчване за отделен обект от земната повърхност.

Получаването на достоверна и надеждна информация за текущото състояние на изследвания обект от земната повърхност по МКСД получени при дистанционни изследвания зависи от:

- познаване специфичната форма на спектралната характеристика за конкретно изследвания обект, както и на нейната динамика в зависимост от текущото състояние на обекта (напр. при стрес предизвикан от засушаване спектралната характеристика на растителността се променя най-забележимо в близката инфрачервена област – (Янев, 1995);
- характеристиките на конкретната измервателна апаратура, най-важни сред които са: спектралния обхват, броя и разположението на измервателните канали (спектралните интервали), пространствена и спектрална разделителна способност, отношение сигнал/шум на отклика на измервания сигнал в канала;
- приложената методика при провеждане на експериментите – осветеност, калибриране, астрономическото време за провеждане и др.;
- правилния подбор на методите за предварителна обработка и последваща тематична интерпретация на получените от ДИ данни.

Задачата за разпознаване, т.е. за идентификацията на различни класове обекти или на различаване на подобекти в рамките на един спектрален клас (този термин е дефиниран в (Campbell,2011)), е основана върху различията в отразителната способност на отделните обекти, като функция от дължината на вълната на електромагнитния спектър или на функционално преобразуване на тези стойности.

От получените при ДИ данни се извлича надеждна информация за текущото състояние на обекти от земната повърхност, изследвайки енергетичното и спектрално разпределение на отразената от тях слънчева радиация, както и времето изменение на тези характеристики. Те намират приложение в широк спектър от области на науката и практиката – метеорология, геофизика, геология и др. За решаване на всяка една специфична задача от тези научни области се подбират характерни дължини на вълната за отразената от изследвания обект слънчева радиация. Например, за нуждите на геоложко картиране на конкретен район е необходимо да се получат данни от лабораторни или полеви измервания добре характеризирани всеки от представените в изследвания район литоложки типове (представителна за тях е близката инфрачервена област –  $1\div 2,5\mu\text{m}$  (ДИ,1983)). Прилагайки класификация без обучение по алгоритъма на K-средните върху данните се отделят основните литоложки типове. След това на базата на допълнителна спектрална информация за всеки един от тези основни класове, както и резултати от наземни и лабораторни многоканални спектрални измервания се формират подкласове и с тяхна помощ се извършва окончателна идентификация на всеки един от обектите. Крайният резултат от обработката на данните от ДИ е получаването на геоложка карта на района в определен мащаб, която допълва или замества съществуваща геоложка карта.

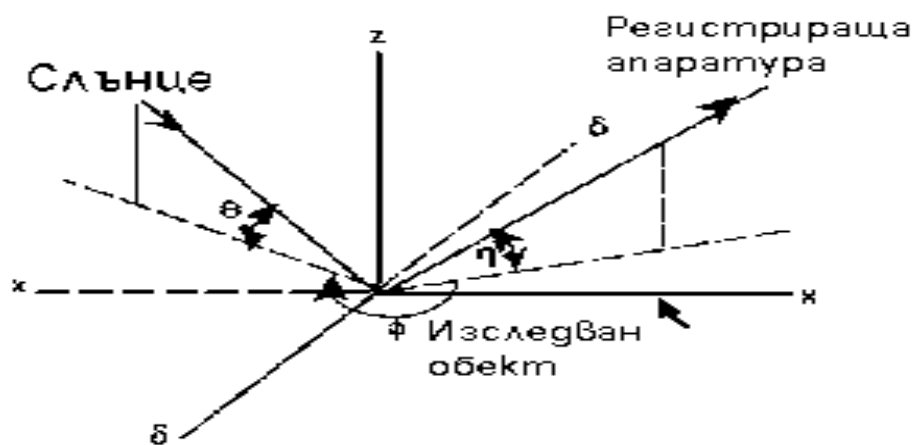
Друг пример за използване на МКСД от ДИ е при извършване оценка на текущите размери на водни площи, както и да бъде получена информация за екологичното състояние на прилежащите им брегови участъци (Николов, 2013). В този случай се използват се различията между спектралните данни за еталонни незамърсени части от водния басейн и такива части, за които се предполага, че съществуват екологични замърсявания. В случаите на замърсявания на участъци от морски басейни с нефт и/или механични замърсявания добра различимост на засегнатите площи се постига при дължина на вълната  $\lambda=0.4\ \mu\text{m}$  или  $0.6\ \mu\text{m}$ . В случаите на хлорофилно замърсяване (т.нар. цъфтеж на водорасли) има характерни екстремуми в СОХ, единият от които е на поглъщане при  $\lambda=0.43\mu\text{m}$  и един на отражение при  $\lambda=0.55\ \mu\text{m}$  и за неговото регистриране се прилага специфичен индекс (Николов, 2014).

## 2.2 Експеримент при дистанционни изследвания

В процеса на получаване на данни от дистанционни изследвания участват следните компоненти: обект на изследване, източник на електромагнитна енергия, преносна среда и регистрираща апаратура.

В практиката на ДИ е прието да се разглеждат два типа експерименти – пасивни и активни (Токарева,2010) (Mather, 2004). При пасивните основен източник на електромагнитна енергия, падаща върху изследваните обекти от земната повърхност е Слънцето. В този случай се регистрира отразеното от обекта излъчване, както и добавената компонентната на собственото му излъчване. За провеждане на активен експеримент е необходимо конкретния обект на изследване да бъде облъчен от специален източник с предварително известни параметри на електромагнитно излъчване (светлинен или радио импулс), а регистрацията на отразеното от него лъчение да се извърши в същия този момент или в много кратък интервал след това.

И в двата случая от получаваните данни, в зависимост от типа на използваните датчици (сензори), се извлича информация за количеството отразено и собствено излъчване на изследвания обект в определени части на електромагнитния спектър достигнало до приемника. Най-често тези характеристики са получени по следната схема: излъчената от Слънцето (или друг източник) електромагнитна енергия преминала и трансформирана от атмосферата попада върху изследвания обект като част от нея се отразява от обекта или се поглъща от него. След това отразената и/или излъчена от обекта електромагнитна енергия преминава отново през атмосферата, където отново е подложена на трансформация и едва тогава се регистрира от системата за получаване на данни. В идеалния случай от регистриращата апаратура би следвало да се получи изходен сигнал, даващ количествена представа за начина, по който обекта отразява и/или поглъща попадналата върху него електромагнитна енергия (вж. Фигура 1).




Фигура 1 Примерна схема на експеримент за дистанционни изследвания (Мишев, 1981).

Най-често използваните области от електромагнитния спектър за ДИ са (вж.Фигура 2) – видимата област ( $0,38\div 0,72\mu\text{m}$ ), близката инфрачервени област ( $0,72\div 1,3\mu\text{m}$ ), няколко тесни участъка от инфрачервената област и далечната (топлинна) инфрачервена област ( $1,5\div 1,8\mu\text{m}$ ,  $2\div 2,6\mu\text{m}$ ,  $4,2\div 5\mu\text{m}$ ,  $7\div 15\mu\text{m}$ ) и СВЧ областта ( $1\text{mm}\div 10\text{cm}$ ).

В исторически план най-широко приложение са получили ДИ във видимата и близките инфрачервени области. Основните ограничения при получаване на данни от дистанционни изследвания в споменатите диапазони се налагат от средата на разпространение на радиацията, която в общия случай се изпълнява от атмосферата. Тези ограничения се изразяват в наличието на области на пропускане на електромагнитната енергия от нея (т.нар. атмосферни прозорци), в които е възможно получаване на спектрални данни от дистанционни изследвания. (ДИ, 1983)





Фигура 2 Спектрален обхват използван в дистанционните изследвания (Мишев, 1981)

Както е показано на Фигура 2 видимата област на електромагнитния спектър (ЕМС) е с най-широка лента на пропускане и в нея се намира значителна част от излъчената от Слънцето енергия, обуславящо нейната добра усвоеност и потенциално максимална информативност, но работейки в нея следва да се отчита наличието на външни смущаващи фактори (напр. атмосферните въздействия), както и фактът, че при пасивни експерименти е необходим външен източник на електромагнитна енергия (най-често Слънцето).

Обемът на получаваните при дистанционни изследвания на Земята данни се определя от възможностите на регистриращата част на апаратурата след тяхното цифроване и запис на бордовия носител.<sup>4</sup> След извършване на радиометрични и геометрични корекции тези данни се привързват към съществуваща карта на определен район от земната повърхност и в зависимост от решаваните задачи се извършва тяхната тематична интерпретация.

Както бе споменато по-горе основните ограничения при получаването на МКСД за изследвания обект при ДИ се налагат от преносната среда между регистриращата апаратура и източника на излъчване. В най-често срещания случай ролята на преносна среда изпълнява атмосферата като нейното влияние върху получаваните данни основно се изразява посредством два механизма на взаимодействие – на разсейване и на поглъщане на енергията постъпваща от източника на радиация и на тази отразена от обекта.

За разсейване се говори, когато преминаващото излъчване се отразява или пречупва от намиращите се в атмосферата газови молекули, прахови частици или водни капки. Друг фактор, който има ключова роля при определяне относителния дял на разсейването или поглъщането в общото влияние на атмосферата върху получаваните МКСД са метеорологичните параметри на атмосферата (температура, налягане). Поради това е необходимо да има налична информация за тях, която се използва при извършване на т.нар. атмосферна корекция на данните от ДИ.

### 2.3 Отражена и собствена радиация, спектрални отразителни характеристики на природните образувания

Стойността на спектралната яркост  $L$  на изследвания обект зависи от интензитета на падащата радиация  $E_0(\lambda_i)$  и неговите отразителни свойства –  $L(\lambda_i, \theta, \varphi) = f[E_0(\lambda_i)]$ . При фиксирани условия на осветяване за определено направление  $(\theta, \varphi)$  и определена дължина на вълната  $\lambda_i$  се дефинира спектралният коефициент на отражение (СКО)  $r(\lambda_i, \theta, \varphi) = L(\lambda_i, \theta, \varphi) / E_0(\lambda_i)$ ,

<sup>4</sup> Например за сателита Ландсат 7 бордория носител е проектиран да съхранява 350MB, което се равнява на 100 сцени.


където  $L(\lambda_i, \theta, \varphi)$  е яркостта в дадено направление, а  $L(\lambda_i)$  е яркостта на ортотропна повърхност при същите условия. (Мишев, 1981).

Спектралният коефициент на отражение  $r$  е безразмерна фотометрична функция характеризираща структурата на разсеяното от обекта излъчване, както по дължина на вълната, така и в зависимост от условията на осветяване (Mather, 2004). В идеалния случай спектралните отражателни характеристики се получават като се изчисли СКО за всички дължини на вълната. Най-често се приема, че  $\theta=0$  и тогава СКО е функция само на  $\lambda$  т.е.  $r(\lambda_i)$  при постоянен zenитен ъгъл. При измерване на СКО на природни обекти се приема, че за времеви интервал на провеждане на експеримента Слънцето е стабилен източник с постоянна характеристика и в този случай измервайки промените в отразената яркост  $L(\lambda_i, \theta, \varphi)$  се отразяват еднозначно и в СКО. Това означава, че е възможно да се отличават отделни обекти на базата на СКО или да се определят различни състояния на един и същ обект в рамките на по-голям период от време.

В най-общия случай СКО зависи от координатите на източника на радиация (Слънцето) и на регистриращата апаратура:

$$r(\lambda_i, \theta, \varphi, Z_{\text{sun}}, \theta_0) = L(\lambda_i, \theta, \varphi, Z_{\text{sun}}, \theta_0) / L_0(\lambda_i), \quad [1]$$


След преобразуванията се вижда, че СКО се изразява като отношение на отразената от реална отразяваща повърхност радиация и отразената радиация от идеална дифузно отразяваща повърхност. На фигурата по-долу са показани примерни спектрални характеристики (криви на СКО), които са получени с интерполация между спектралните канали, в които е регистрирана отразената радиация.



Фигура 3 Примерни спектрални отражателни характеристики на някои основни типове обекти от земната повърхност (Мишев, 1981)

## 2.4 Методи и апаратура за измерване на отразена радиация във видимата и близката инфрачервена области на електромагнитния спектър

При ДИ основният прибор за регистрация на отразената слънчева радиация във видимата област и излъчената от обекта електромагнитна енергия в близката инфрачервена област е многоканалната спектрометрична апаратура (МКСА). Най-общата схема на МКСА се състои от следните основни възли – входна апертура, фокусираща оптика, диспергираща оптика, изходна апертура и сензор/и. Посредством, описаните основни възли на регистриращата апаратура се получават цифрови данни, които е могат да бъдат интерпретирани, като спектрална плътност на енергетичната осветеност при фиксирана дължина на вълната. В най-често срещания случай се измерва отразената радиация от обект осветен от външен за апаратурата източник (еталонен източник на светлина или Слънцето), аналогично е измерването и на собственото излъчване на обекта. Съставна част на при някои реални сателитно или аеро базирани МКСА е наличието вътрешен еталон, който служи за валидиране (калибровка) на апаратурата по време на работа.



Фигура 4 Пример за един ред на сканиране с отклик за всяка една от спектралните интервали -Landsat TM

В основата на описания по-горе базов модел на спектрометър са детекторите, защото те регистрират постъпилото излъчване и го преобразуват в цифров вид. В последните години в практиката на ДИ широко навлизат системи, формиращи спектрални изображения в голям брой спектрални канали. Те се характеризират с ширина (спектрален интервал), централна дължина на вълната и спектрална чувствителност. Тези системи работят с два типа сканиращи сензори с линейна или матрична структура. Всеки един пространствен елемент от изследваната повърхност се проектира върху елемент от сензора на апаратурата, за който се получават пространствени координати и спектрални данни. Технологиите за получаване на двумерно оптично изображение е различна при сателитно-базираните спектрометрични системи и в исторически план се е променяла значително. Поради този факт конкретна реализация на МКСА няма да бъде разглеждана в подробности в тази дисертация.

Изхождайки от изложеното в тази глава могат да се направят следните изводи:

- дистанционните изследвания на Земята са съвременна и бързоразвиваща се мултидисциплинарна област, обединяваща постижения с теоретичен и приложен аспект и позволяваща решаване на широк спектър приложни задачи;
- те се основават на теоретични закони от различни дялове на физиката, което е предпоставка за създаване на иновативни инженерни и технологични решения за получаване на МКСД от ДИ;
- информацията извлечена от МКСД позволява установяване на моментното състояние на обекти от повърхността на Земята, както и проследяване на тяхната времева динамика;
- тази информация е надежден източник за създаването на тематични карти и разработване на модели за вземането на обосновани решения при управление на територии;
- важна особеност е, че при получените от ДИ крайни продукти съотношението цена/разходи е на порядък по-ниско в сравнение със сходни такива получени по други методи.

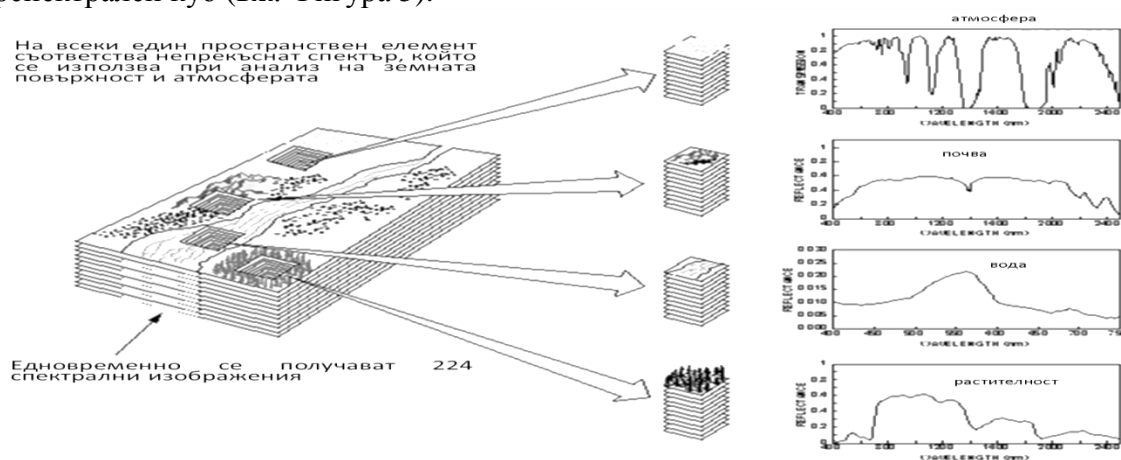
### Глава 3. Получаване на многоканални спектрални изображения при дистанционните изследвания

#### 3.1 Многоканални спектрометрични системи – видове, принцип на действие, характерни особености

При ДИ основен носител на информация относно яркостта на изследваните обекти от повърхността на Земята са МКСИ получавани в два или повече спектрални интервали с ширина  $\Delta\lambda$  като тенденцията е тази ширина да намалява, а броят интервали да се увеличава. В

така полученото цифрово изображение яркостта на всяка отделна точка (пиксел<sup>5</sup>) отговаря на отразеното или собственото излъчване на изследвания обект (Wade, 2006). Яркостта на всеки един пиксел се регистрира от отделен елемент на детектора и неговият размер разгледан съвместно с оптичeskата система определят размера на най-малката площ от обекта, която може да бъде изследвана.

Независимо от конкретно използвания принцип регистрирания от фоточувствителната структура сигнал носи информация относно яркостта на пикселите, описващи изследвания обект в определен спектрален интервал, както и тяхното положение в пространството. Последната стъпка при получаване на МКСД е данните за всеки един спектрален канал да се преобразуват в цифров код посредством дискретизация с фиксиран брой нива<sup>6</sup>, след която резултантното изображение има вида, показан на Фигура 6. При МКСА формиращи изображение броят единични изображения (спектрални слоеве) е равен на спектралните канали. При съвременните аеро или сателитнобазирани многоканални спектрометрични комплекси, броят спектрални канали е над 200 като например за AVIRIS<sup>7</sup> те са 224, а за HYPERION<sup>8</sup> са съответно 220 и при тях регистрираните МКСД формират т.нар. хиперспектрален куб (вж. Фигура 5).



Фигура 5 Пример за получаване на многоканално (хиперспектрално) изображение и еталонни спектрални характеристики на някои видове обекти от земната повърхност (по данни от AVIRIS)

Данните получавани от МКСА, базирана на спътници за наблюдение на Земята, които са на ниска околоземна орбита (low Earth orbit – LEO) напр. Landsat, SPOT, Aster и др., като правило са от по-широки спектрални интервали (десетки nm), а самите данни са интегрална реакция в конкретната спектрална зона. Тези данни се представят от цифрови стойности в определен интервал (при по-старите системи той е 0÷255, което съответства на дискретизация на реалния аналогов сигнал с 8 бита, а при съвременните дискретизацията е съответно 11 бита – Iconos, Quickbird и 12 бита – ALI/OLI/MSI) и са познати като цифрови стойности (DN) за МКСД.

Преобразуването към реална физична величина на безразмерните DN в стойности съответстващи на отражателната способност на обекта (reflectance) се извършва посредством процедура утвърдена от метрологичен орган и организацията експлоатираща конкретната МКСА и на базата на корекционни коефициенти за всяко МКСИ, съдържащи се в придружаващия файл с метаданни. Проведените в рамките на това изследване експерименти и получаваните резултати са базирани на преизчислени DN стойности<sup>9</sup> към енергетична яркост регистрирана от сензора (Top of the atmosphere radiance - TOA)<sup>10</sup>. Това гарантира коректна

<sup>5</sup> pixel – Picture Element

<sup>6</sup> Този брой определя радиометричната чувствителност на апаратурата


<sup>7</sup> General Overview – AVIRIS, <http://aviris.jpl.nasa.gov/aviris/index.html>

<sup>8</sup> EO-1 User Guide v. 2.3, <http://eo1.usgs.gov/documents/hyperion>

<sup>9</sup> За Landsat стойностите за DN са получени в резултат на обработката им до ниво L1T

<sup>10</sup> [http://earth.esa.int/pub/ESA\\_DOC/landsat\\_FAQ/](http://earth.esa.int/pub/ESA_DOC/landsat_FAQ/), [http://landsathandbook.gsfc.nasa.gov/data\\_prod/prog\\_sect11\\_3.html](http://landsathandbook.gsfc.nasa.gov/data_prod/prog_sect11_3.html) .

интерпретацията на данните и по-висока точност при класификация, което води до бързо създаване на актуални тематични изображения и информационни услуги базирани на МКСД.



Фигура 6 Примерно изображение в един спектрален канал след цифроване при пет нива на дискретизация – в този случай максималната стойност на DN е 32

### 3.2 Получаване на еталонни многоканални спектрални данни за обекти от земната повърхност

При провеждане на експеримент, прилагащ технологията на ДИ с оглед коректната интерпретация на регистрираните МКСД за отразеното и собствено излъчване на природните образувания е необходимо наличие на допълнителна информация за конкретно изследваните природни и антропогенни обекти. Тя се получава посредством наземни контактни и/или безконтактни измервания като за всяка конкретна задача се измерват различен набор физични параметри (отразена и собствена радиация, температура, влажност, водно съдържание и др.), както и данни от предходни експерименти. Нейната функция е да подпомогне в максимална степен еднозначното идентифициране на изследвания обект на базата на неговия СКО, както и да опише условията, при които са получени данните от дистанционни изследвания.

Изложеното дотук дава основание при провеждане на експеримент посредством ДИ да се постави следното изискване – едновременно с експерименталните данни да се получат допълнителни спектрални данни и други съпътстващи данни за конкретния обект от in-situ наблюдения. Тези наземни данни служат за създаване на гео-база данни (ГБД) насочена към по-пълно описание на конкретен обект от земната повърхност. Тяхното наличие би повишила надеждността на получаваните от нея резултати, когато се налага да извърши обобщаване за всеки един изследваните типове обекти въз основа на МКСД. В нея основно място заема набора от криви на СКО, които се приемат за еталонни и по този начин се създава т.нар. спектрална библиотека<sup>11</sup>. За СКО също така се приема, че характеризират еднозначно даден природен или антропогенен обект т.е. формира се еталонен образ в пространството на спектралните коефициенти на отражение, които са в основата на процедура за изграждане на коректно съответствие между конкретен обект на изследване и предварително описан от спектрална крива обект.

Количеството на необходимите еталонни обекти за един район се определя от броя на различните природни/антропогенни образувания включени в изследването т.е. от броя информационни класове, които ще бъдат изследвани в рамките на конкретна задача. Този брой е от особено значение, тъй като той определя размера на обучаващото множество, с което ще се извършва обучението на модела, извършващ тематичната класификация на МКСД. От него зависи и доколко коректно ще бъде описан даден клас обекти, но от друга страна той не следва да бъде и прекалено голям, защото вземайки по-голям брой пиксели се получават нежелани вариации вътре в разглеждания клас, дължащи се на спектрална нехомогенност. При реализация на процедура за тематична класификация още един фактор,

<sup>11</sup> Към момента са налични 20 интернет-базирани спектрални библиотеки, предлагащи еталонни спектрални характеристики за различни обекти в графичен и табличен вид напр. <http://speclib.jpl.nasa.gov/>

който следва да се вземе предвид с оглед подобряване на крайната точност е размера на изследваната територия и в съответствие с нея да бъде подбрана подходяща ПРС за МКСД. При изследване на по-малки площи от земната повърхност се предпочита по-висока ПРС (0.5м до 10м), което в по-голяма степен елиминира проблема “смесен клас” (Lu, 2007), докато при създаване на регионални или глобални модели като правило се прилага по-ниска ПРС (300м – 1км).

### 3.3 Предварителна обработка на данните, получавани от МКСА.

При получаване на данни от ДИ е необходимо да се вземат мерки за намаляване влиянието на външните фактори. Тяхното влияние се компенсира на етапа на предварителна обработка на МКСД, в който се включват три основни процедури: за спектрометрична, радиометрична и за геометрична корекция.

Радиометричната корекция включва нормиране чувствителността на получаваната от МКСА информация за яркостта на природните образувания. Основната цел е да се намали допусканата грешка при интерпретация и количествен анализ на стойностите за яркостта. Затова радиометричните грешки се разглеждат като шум предизвикан от пространствени или времеви промени в яркостта на изображението, които не са свързани с изследвания обект. Най-голям дял в привнесената в данните радиометрична грешка се дължи на избрания модел на атмосферата.

Посредством извършване на геометрични корекции в получаваните МКСИ е възможно да бъдат коригирани геометрични неточности използвайки данни за положението на регистриращата апаратура в пространството и познавайки изкривяванията внасяни от оптичната система на апаратурата. За отстраняване на този тип грешки се прилагат следните подходи - корекция посредством или с помощта на корекция между две изображения, едното от които е прието за еталон.

#### 3.3.1 Използване данни от многоканални спектрометрични системи със средна ПРС – ТМ, ЕТМ+, ОЛИ

Като един наложил се в последните десетилетия надежден източник на МКСД при изследване на обекти от повърхността на Земята посредством дистанционни методи е Геоложката служба на САЩ (USGS). Тя поддържа богат архив от МКСИ получавани от многоканалните спектрални апаратурни комплекси ТМ, ЕТМ+ и ОЛИ (вж. Таблица 1) разположени на борда на сателитите от серията Landsat и осигурява свободен достъп до тях<sup>12</sup>. Предварителната обработка на самите изображения до ниво 1 от Level 1Product Generation System (LPGS) е автоматизирана, като МКСИ имат следните параметри: файлов формат GeoTIF, ресемплирано по метод кубична конволюция; ПРС 30м<sup>13</sup>; проекция UTM към датум WGS84, както и метаданни към тях.

ТМ и ЕТМ+	ОЛИ	Дължина на вълната, $\mu\text{m}$	ПРС, m	Основно предназначение (Landsat, 2015)
–	Канал 1	0.43 – 0.45	30	наблюдения на бреговата ивица
Канал 1	Канал 2	0.45 – 0.52	30	картиране на водни повърхности; разграничава почва от растителност; широколистна от иглолистна растителност
Канал 2	Канал 3	0.52 – 0.60	30	характерен за растителността пик, който се ползва за оценка за жизнеността ѝ
Канал 3	Канал 4	0.63 – 0.69	30	формира характерен за растителността наклон, дължащ се на силно поглъщане от хлорофила в растенията
Канал 4	Канал 5	0.76 – 0.90 / 0.85 – 0.88	30	подчертава съдържанието на биомаса в растителността; очертава бреговата линия за морета и океани
Канал 5	Канал 6	1.55 – 1.75 / 1.57 – 1.65	30	използва се за определяне съдържанието на влага в почвата и растителността; прониква през тънки облаци.

<sup>12</sup> В този архив са налични и данни от други МКСА, но те не се разглеждат тъй като в тази дисертация не са използвани.


<sup>13</sup> Съгласно възприетата в последните години класификация за геопропространствени данни ПРС 30мх30м се приема за средна.

TM и ETM+	OLI	Дължина на вълната, $\mu\text{m}$	ПРС, m	Основно предназначение (Landsat, 2015)
Канал 6	Канали 10 и 11	10.40 – 12.50/ 10.60 – 11.19 и 11.50 – 12.51	60/100 <sup>14</sup>	картографиране на базата на топлинно излъчване и прогнозиране на влага на почвата
Канал 7	Канал 7	2.09 – 2.35 / 2.11 – 2.29	30	картографиране на хидротермално променените скали, свързани с минерални залежи
Канал 8 (само за ETM+)	Канал 8	0.52 – 0.90 0.50 – 0.68	15	визуална ориентация и <i>панишарп</i> на МКСИ
–	Канал 9	1.36 – 1.38	30	разграничава перести облаци

Таблица 1 Спектрални канали за TM, ETM+, OLI и техните основни области на приложение.

Приложимостта на МКСД за решаване на конкретна задача свързана със идентификация на основни типове обекти от земната повърхност по данни от споменатите МКСА се извършва като вземе еталонна крива на СКО за даден обект и се сравни със спектралните интервали на съответната МКСА (вж. Фигура 7).

Първа и необходима стъпка за да бъде постигната съпоставимост на данните от ДИ (за конкретния случай от TM/ETM+/OLI) и данни получени при наземни полеви измервания е измерените величини да са с еднаква дименсия  $[\text{W}\cdot\text{m}^{-2}\cdot\text{sr}^{-1}]^{15}$ , която съответства на отражателната способност за конкретен, реален обект. Повечето полеви прибори предоставят данни отговарящи на това условие, но данните от TM/ETM+/OLI са в DN. Това налага те да бъдат преобразувани към тази величина със същата дименсия. Процедурата, която следва да се използва за преобразуване на DN в отражателна способност е описана подробно в (LandsatHandBook, 2014).



Фигура 7 Примерни спектрални криви на широколистна растителност (A), мътна вода (B) и минерал гьотит (C) спрямо спектралните канали на ETM+

В проучената литература са посочени два варианта на коефициенти за преизчисляване на данните от TM/ETM+ към TOA и в дисертацията те бяха разгледани и оценени. Кривите на получени в резултат на преизчисляване на данните за клас 311 по КЗП с двата набора коефициенти са представени на фигура 8, а най-близко до еталонната характеристика на спектрално отражение посочена на Фигура 7 за същия клас са получените характеристики с коефициентите от ЕКА<sup>16</sup>.


На Фигура 9 са показани абсолютните стойности на разликите между DN за оригиналните и преизчислените данни в съответствие с цитираните формули по спектрални интервали за двете изследвани години (1999 и 2006) за клас 512 КЗП. Различията в стойностите за ИЧ

<sup>14</sup> И за двете МКСА в крайния продукт са ресемплирани до 30м.


<sup>15</sup> <http://graphics.stanford.edu/courses/cs448-05-winter/papers/nicodemus-brdf-nist.pdf> page vi

<sup>16</sup> Questions and answers, ESA, [http://earth.esa.int/pub/ESA\\_DOC/Landsat\\_FAQ.pdf](http://earth.esa.int/pub/ESA_DOC/Landsat_FAQ.pdf), accessed July 14 2009

област обосновават необходимостта от провеждането на споменатата по-горе трансформация върху МКСД с оглед постигане на по-висока точност при последваща тематична класификация.



Фигура 8 Усреднени стойности на данни за енергетичната яркост (ТоА) за клас311 по КЗП, прилагайки формулите указани от ЕКА и ГСлСАЩ



Фигура 9 Разлики между оригиналните и преизчислените към ТоА DN стойности за клас 512 по КЗП.

### 3.3.2 Подобряване идентификацията на обекти от земната повърхност след отчитане влиянието на терена

Изхождайки от факта, че сателитно или аеро базиран МКСА за ДИ наблюдава определена част от земната повърхност от един постоянен ъгъл, а в същото време релефа на земната повърхност е разнообразен, получаваните стойности за DN варират в зависимост дали са разположени в осветена или сенчеста част от терена. На Фигура 10 са показани две характеристики на спектрално отражение за един и същ вид растителност в зависимост от склона, на който е разположена. Разглеждайки само абсолютните стойности на отражението е възможно този обект да попадне в различни класове и следователно да бъде некоректно класифициран. Едно възможно и несложно решение за минимизиране ефекта на текущия ъгъл на Слънцето в момента на получаване на данните върху стойностите на отражение<sup>17</sup> се базира

на следната формула  $DN_{corr} = \frac{DN}{\sin \alpha}$ , която е цитирана и в (Tempfli, 2009). За прецизна корекция на топографските ефекти (наклон, изложение) върху МКСД има разработени физико-математически модели<sup>18</sup> за тяхното преобразуване с цел минимизиране на тяхното влияние.

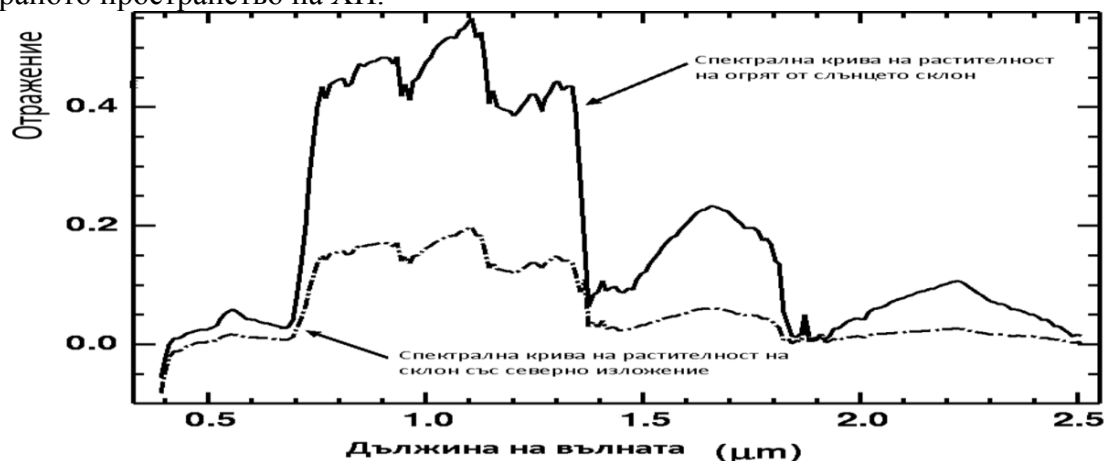
<sup>17</sup> [http://www2.gi.alaska.edu/~rgens/teaching/asf\\_seminar/corrections.pdf](http://www2.gi.alaska.edu/~rgens/teaching/asf_seminar/corrections.pdf)

<sup>18</sup> Емпирични модели и радиационни преносни модели (Zhang, 2011)



### 3.4 Интерпретация в пространство на признаците. Обучение на класифицираща процедура

При експеримент за ДИ на базата на измерена спектрална отразателна характеристика  $r(\lambda)$  за даден обект, както и с използването на допълнителни данни, е необходимо да се извърши максимално достоверно причисляване на конкретен обект към предварително известна и характеризирани по-голяма група обекти. По този начин се формира *пространство на характеризиращите признаци (ХП)*. Всички по-нататъшни разсъждения и моделни изчисления относно идентификация на обекти от земната повърхност се провеждат в така дефинираното пространство на ХП.



Фигура 10 Промяна в отразателната способност на растителност в зависимост изложението.

В по-общ смисъл определението за признак има смисъл на обем информация, която е полезна при вземане на решение относно причисляване на даден обект към един или друг клас (ДИ, 1983). В процеса на решаване на конкретен практически проблем от първостепенна важност е да се намали размерността на пространството на признаците с цел улеснение при извършване на последващи изчисления. Един често прилаган подход за достигане до това пространство е анализ на главните компоненти (АГК)<sup>19</sup>, но успешно се прилагат и други<sup>20</sup>.

Получавайки МКСД, отнасящи се към едни и същи обекти от земната повърхност, най-често тяхното представяне в пространството на ХП не е с една единствена точка, а „облак“ стойности (вж. Фигура 11).

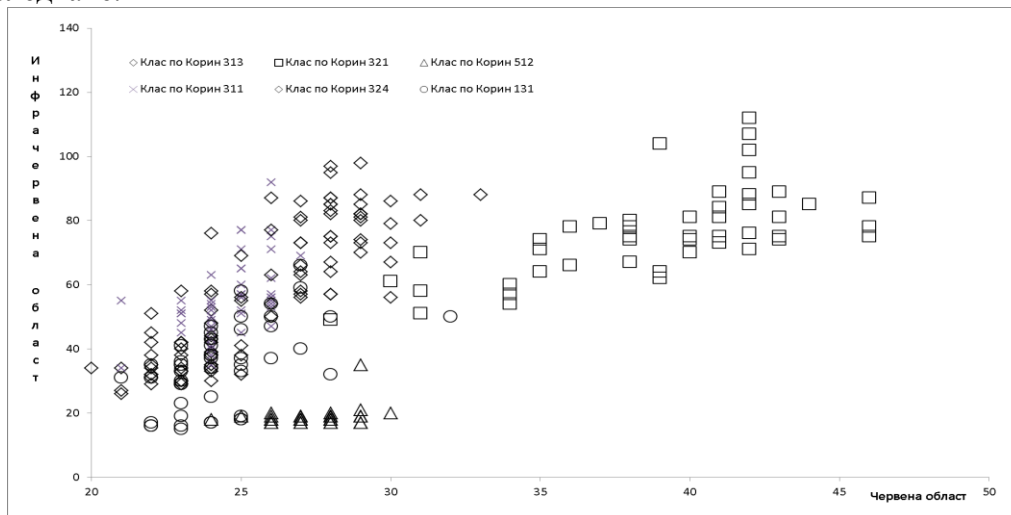
Описаната в (Campbell,2011) процедура за тематична класификация на всеки конкретен обект трябва да осигури съответствие между предварително формирани спектрални класове и търсени информационни класове. За решаване на този проблем най-широко приложение за разделяне на подобластите от пространството на ХП е намерил методът използващ дискриминантни функции  $D(X)=\{D_1(X)...D_n(X)\}$  (най-често линейни) като е необходимо техният брой да е равен на размерността на пространството на признаците. Тези функции имат следното свойство: *за всеки от разглежданите вектори  $X=|\lambda_1... \lambda_n|$  една от дискриминантните функции има максимална стойност*. И тогава причисляването на конкретен вектор  $X$  към дадена подобласт се свежда до изчисляване стойностите на  $D(X)$ , намиране на тази функция имаща максимална стойност за конкретния вектор  $X$  и по този начин този вектор  $X$  се причислява към съответната подобласт в пространство на ХП (наричана в някои източници клъстер).

В процеса на класификация на данни от ДИ се прилагат два метода – класификация без обучение (клъстеризация) и класификация с обучение. Както е посочено в (Yang,2009), разглеждан самостоятелно всеки един от споменатите методи има своите ограничения, които е невъзможно да бъдат преодолени. Доста често се прилага комбинация от двата метода с цел

19 Principle Component Analysis – PCA

20 Decision Boundary Feature Extraction – DBFE (Landgrebe, 1999)

максимална ефективност при липса на достатъчно допълнителна информация за конкретния район на изследване.



Фигура 11 Основни типове земна повърхност в район около рудник "Медет" представени в пространството на спектрални области червена и близка инфрачервена (Nikolov, 2011)

Методът за класификация без обучение предполага прилагане на алгоритъм за намиране на "естествено" групираните в пространството на ХП обекти от цялото МКСИ. След края на процедурата се допуска, че всяка формирана група (клъстер – спектрален клас) представлява разпределението на вероятността за всеки един клас от класовете, представляващи интерес.

Прилагането на класификация с обучение на МКСД предполага, че е възможно на базата на данни от наземни изследвания, карти, снимки и др. да се локализируют малки хомогенни области в МКСИ, в които със сигурност са разположени обектите, представляващи интерес за конкретното изследване. От тях се формират извадките за обучение и валидация на модела, който ще се създава за извършване на тематичната класификация.

### 3.5 Класификация в пространство на признаците чрез функция на разстоянието.

В зависимост от използвания брой признаци класификацията се реализира посредством разделяне на пространството на ХП на подобласти с помощта на криви, повърхнини, хиперравнини, осигуряващи максимална разделимост на данните. Например ако се разгледа двумерно или тримерно пространство на ХП един лесен за реализация модел е показан на Фигура 12.

При формиране на подобластите в пространството на ХП, съответстващи на всеки един спектрален клас, най-широко прилаганата стратегия е да се използва критерият на Бейес за минимален среден риск. За да е възможно тя да бъде приложена е необходимо да се изчислят многомерните функции на плътността  $p(X|i)$  за всеки един клас, използвайки формулата:

$$P(X | \omega_i) = \frac{1}{2\pi^{n/2} \sqrt{|\Sigma|}} \exp\left(-\frac{1}{2} (X - M_i)^T \Sigma_i^{-1} (X - M_i)\right) \quad [6]$$

В разглеждания случай е в сила предположението, че всяка една функция  $p(X/i)$  има нормално разпределение.

При класификация използваща функция на разстоянието за дискриминантната функция  $D_i(X)$  имаме:

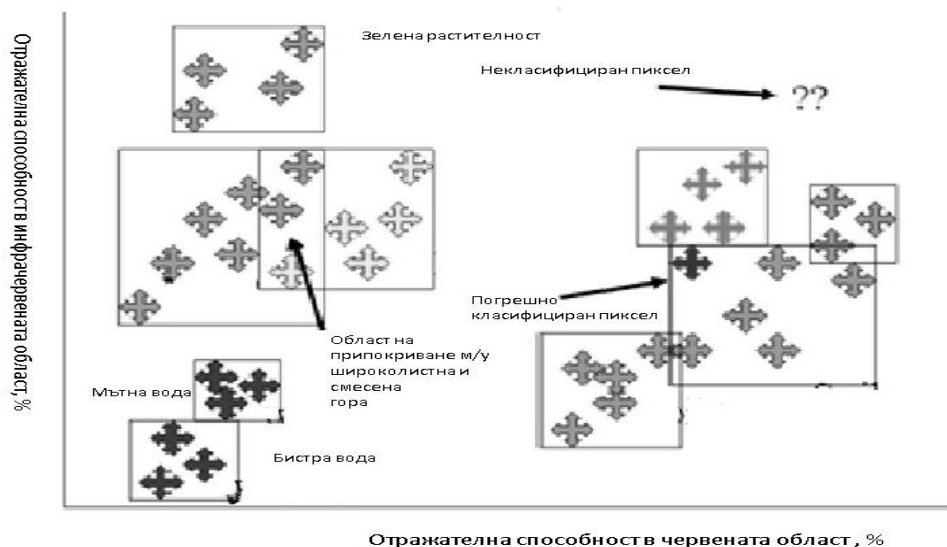
$$D_i(X) = A - \frac{1}{2} (X - M_i)^T \Sigma_i^{-1} (X - M_i) \quad [7]$$

където  $A$  е константа и може да бъде пренебрегната когато се сравняват  $D_i(X)$  за различни класове, а вторият член на уравнението се нарича разстояние на Махаланобиус и се прилага за причисляване на конкретния пиксел към предварително дефиниран клас като се взема най-малката стойност на  $D_i(X)$  (Schowengerdt, 1983).

Ако приемем, че признаците нямат корелация и имат равни дисперсии по всяка една от осите на признаците:

$$D_i(X) = A - \frac{(X - M_i)'(X - M_i)}{2\sigma^2} \quad [8]$$

която описва дискриминантната функция на класификация по минималното разстояние.



Фигура 12 Класификация, използваща фигури с прави ъгли (правоъгълник при 2 ХП и паралелепипед при 3 ХП).

Описаните по-горе методи за клъстер анализ са разработени с цел проява на съдържащите се в данните свойства да се групират около определени центрове в пространството на ХП. Допускането, че тези центрове съвпадат с максимума на нормално разпределени величини (вж. формула [6]) лежи в основата на клъстерния анализ. В случай че даден клас има многомодално разпределение за да се приложи този подход е възможно той да се разбие на определен брой едномодални класове т.е. да се формират подкласове. Друга негова важна особеност е, че този анализ протича без външна намеса (т.е. това е процес на неконтролируема класификация). Дефиницията на понятието клъстер зависи от три помощни понятия - разстояние между точките вътре в класа, разстояние между клъстерите и критерий за формиране на клъстерите.

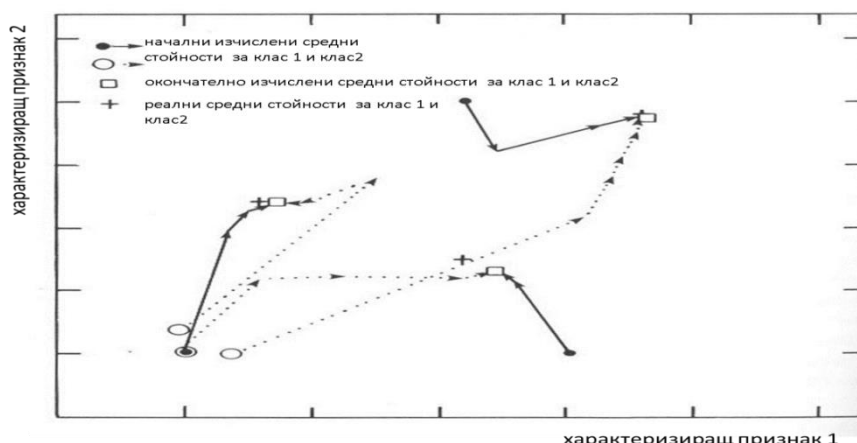
При провеждане на клъстер анализ алгоритъмът за работа е следният. Първо се избират  $N$  вектора с математическото очакване  $M_i$  за центрове на клъстерите като този избор е произволен, но необходимо условие е  $M_i$  да бъдат различни. Стойността на  $N$  се избира завишена с цел максимална разделимост на клъстерите, но след края на процедурата е възможно последващо обединяване на някои от клъстерите за да се избегне излишно раздробяване на пространството на признаците. На втората стъпка на базата на избрания критерий за разстояние между точките вътре в клъстера всяка точка се причислява към един от клъстерите. На третата стъпка се изчислява математическото очакване  $M_i$  за всеки клъстер. Ако новите математически очаквания  $M_i$  са равни с предходните или са в допустима граница, то алгоритъмът спира, в противен случай новите математически очаквания  $M_i$  стават центрове на клъстери и се връща към стъпка втора.

На базата на изложените по-горе теоретични постановки най-широко разпространение при клъстеризация на МКСД от ДИ са намерили алгоритъмът на К-средните (Lu, 2007), който представлява итеративен алгоритъм за формиране на клъстери<sup>21</sup> (вж. Фигура 13) и метода за клъстеризация *Итеративен СамоОрганизиращ се Метод за Анализ на Данни* – ИСОМАД<sup>22</sup>. За

21 За добър обзор по темата виж - [http://isu.indstate.edu/qweng/classification\\_review\\_IJRS\\_2007.pdf](http://isu.indstate.edu/qweng/classification_review_IJRS_2007.pdf) Този алгоритъм или негови модификации ще бъде използван като базов при сравнението между изследваните алгоритми за класификация.

22 Iterative Self Organizing Data Analysis Techniques Algorithm – ISODATA

разлика от алгоритъма на K-средните, при ИСОМАД броят клъстери (т.е. потенциални информационни класове) е предварително зададен и целта е да се минимизират вариациите вътре в тях.



Фигура 13 Намиране на центрове на клъстери за два класа по алгоритъм K-средни.

### 3.6 Статистически подход при класификация с обучение при многоканални данни

Стойностите на получаваните при ДИ МКСД варират в широки граници и е трудно да се направи точно предположение относно принадлежността на всеки пиксел към даден клас. За преодоляване на този проблем се прилага математическия апарат на статистическите методи за формиране на изводи при формулиран критерий за допустимата грешка. Най-често като такъв критерий се използва минимизация на стойността на грешката при класификация за конкретно изследвания набор данни. Така формулираната теоретична постановка прилага оптимална класификация съгласно правилото на Бейес за минимален среден риск на базата на априорните вероятности за поява на всеки един от класовете и изчислена функция за плътността на вероятността за всеки елемент от данните (Campbell, 2011).

Методите за статистическа класификация използват функциите за плътността на вероятността за формиране на класове, но тъй като в общия случай тази функции не са известни затова се използват техни оценки на базата на обучаващи извадки. В зависимост от факта дали видът на функцията е известен или е необходимо да се установи в процеса на класификация методите се разделят на параметрични и непараметрични. В първия случай е необходимо да се оценят параметрите на тези функции (мат. очакване, дисперсия), докато във втория на базата на обучаващите извадки се формират самите функции.

Използването на оптимална стратегия по правилото за максимално правдоподобие означава: ако в дадено изображение се търсят  $n$  класа и са зададени априорните вероятности за поява на всеки един от класовете  $p(i)$ , както и  $i$  функцията на плътността на вероятността  $p(X|i)$ , то тогава  $X$  принадлежи на даден клас от  $n$  възможни само ако  $p(X|i) \cdot p(i) \geq p(X|j) \cdot p(j)$  за всяко  $i, j=1 \dots n$ . В този случай за всеки елемент от МКСД се изчислява  $p(X|i) \cdot p(i)$  и процедурата го причислява към онзи клас, за който това произведение има най-висока стойност (решава се задача за максимизация). При МКСИ априорните вероятности  $p(i)$  се изчисляват за всеки конкретен случай по данни от наземни измервания, карти на района или друга допълнителна информация.

Критерият по който се създава модела на процедурата за тематична класификация в този случай е: *минимизиране на грешката при класификация на всеки един от пикселите от изображението в определен, предварително дефиниран клас.*

При така приетата стратегия за класификация всеки пиксел от МКСИ задължително се класифицира към един от класовете, за който е дефинирана функцията за плътността на вероятността т.е. той винаги попада в един от класовете. В доста случаи се появяват пиксели, които със сигурност не принадлежат реално към нито към един от предварително дефинираните класове, но те биват причислявани към някой от класовете и по този начин се

намалява общата точност при класификация (Фигура 12). За да се избегнат тези случаи потребителя задава гранични стойности за  $p(X/i)$  в началото на класификацията и така се формира отделен клас за откази при класификация (спектрален клас, на който не съответства информационен клас), повишавайки надеждността на крайните резултати за сметка на незначителен брой коректни, но отхвърлени пиксели.

Изложеното в тази глава дава основание да се направят следните изводи:

1. съвременните спектрометричните системи за получаване на МКСД, които са в основата на съвременните сателитно и аеро базирани комплекси за получаване на спектрални данни са надежден източник на данни за обекти от земната повърхност;
2. безвъзмездният достъп до актуални и архивни МКСД със средна ПРС, както и програмно осигуряване за тяхната предварителна обработка, позволява те да бъдат в основният източник на информация при решаване на задачи като част от проекти с научна и приложна насоченост;
3. важно място заема етапа на предварителна обработка на МКСД от сателитни и аеро носители, тъй като тя позволява съвместното им използване с данни от спектрометрични in-situ измервания, което осигурява създаване на еталонни обекти в пространството на ХП;
4. с оглед коректната интерпретация на наличните в МКСД спектрални класове в информационни е необходимо да се изгради пространство на ХП, като най-често такива ХП са СКО, и в него, прилагайки един от двата изложени метода<sup>23</sup> базиран на статистически подход, да се формират дискриминационните функции, които дефинират подобластите за всеки един информационен клас.


#### **Глава 4. Приложение на методологията за разпознаване на образи за класификация на данни от дистанционни изследвания**

В следващите параграфи ще бъдат разгледани теоретичните основи на два метода за създаване на модели за разпознаване на образи<sup>24</sup> с предварително обучение на разпознаващата процедура от налични данни (learning machine approach), при който да се използва способността на използваните данни да се групират в по-големи или по-малки области от пространството на ХП. За да бъде възможно разделянето на тези области една от друга е необходимо да се прокарат разделящите ги повърхнини (линии, равнини, хиперравнини). В голямата си част функциите, които описват тези повърхнини са нелинейни и това е сериозна пречка при използването на статистически методи. Както е посочено в (Lee, 1993) увеличаването броя на характеризиращите признаци разгледано съвместно с относително малкият размер на обучаващата извадка постигане на надеждна оценка на статистическите параметри на извадката е трудно достижима.

При използване на МКСД за създаване на модел за класификация с обучение се наблюдава следната особеност – наличието на краен брой обучаващи данни и увеличаването на броя на използваните ХП води до увеличение на точността при класификация, но съществува стойност на броя ХП след, която точността започва да намалява. Този ефект е познат като “феномен на Хю” (Hughes, 1968) (Pal, 2010) и трябва винаги да се отчита при използване на по-голям брой спектрални канали в процеса на класификация на МКСД (вж. Фигура 14). За неговото преодоляване се прилагат няколко подхода– увеличаване на размера на обучаващата извадка при увеличаване на броя ХП; намаляване размерността на пространството на ХП (напр. прилагайки АГК); използване на методи, които не са чувствителни към него.

<sup>23</sup> Метод на К-средните и ИСОМАД.

<sup>24</sup> Тук под понятието образ ще се разбира вектор с ХП описващи реален обект в пространството на същите ХП.



Фигура 14 Пример за ефект на Хю при нарастване на броя използвани ХП.

Изложеното в предходните параграфи е основна причина в тази дисертация да бъдат приложени нелинейни методи за разпознаване на образи. Тяхното предимство, че позволяват използване на нелинейни дискриминационни функции за разделяне на спектралните класове в пространството на ХП. В този случай под понятието нелинейност ще разбираме:

- преобразуването вход–изход извършвано от модела не е ограничено до линейна функция;
- функцията, на базата на която се извършва оценка качеството на модела (т.е. точността, с която той апроксимира желаните изходни данни на базата на конкретни входни данни) също е нелинейна по отношение на непознати параметри.

Изследваните в тази дисертация нелинейни методи за тематична класификация на МКСИ попадат в категорията на напараметричните методи (Melgani,2004). Непараметричността на тези модели не означава, че параметри като цяло липсват, а напротив те имат ключово значение и са предмет на особено разглеждане и настройка (Kestman,2001). За разлика от параметрите при моделите базирани на статистически подход при нелинейните модели те не са зададени предварително, а техният брой е в зависимост от обема на използваните данни на етап „обучение на модел“ за всеки конкретен случай.

В тази дисертация като основен инструмент за тематична обработка на МКСД от ДИ бяха приложени нелинейни методи за класификация с обучение в следните техни две конкретни реализации – невронни мрежи (НМ), използващи метода на обратно разпространение на грешката при обучение<sup>25</sup> и метод на опорните вектори<sup>26</sup> (МОВ). За получаване на модели по двата метода се следва последователността – етап „създаване на модел“, включващ „обучение на модел“ и „валидация на модел“, и етап „тематична класификация“. Целта и при двата е да се създаде модел за класификация на МКСИ, който предоставя висока точност след прилагането му върху голям обем данни. Общото при тях е, че за създаване на модела, описващ данните се минимизира грешката между получавания от модела резултат след неговото обучение с извадка от набора МКСД и еталонни данни<sup>27</sup>, а разликата се изразява в прилаганите стратегии при нейната минимизация. Например при НМ избирайки подходяща структура (брой на неврони в скрития слой, тип на активационната функция и др.) се запазва доверителния интервал на данните (вж. дефиниция за ERM в раздел 4.2.1 стр. 29) (Stoyanov, 2011), в който е необходимо да се минимизира грешката между желан и реален изход от

<sup>25</sup> Back propagation artificial neural network (BPANN)

<sup>26</sup> Support vector machines (SVM) – при превода на този термин е следвана терминологията от установена в механиката.

<sup>27</sup> Представителни криви на СКО взети от спектрална библиотека (вж. раздел 3.3).

модела, докато при МОВ същата грешка се задава като константа (нула или допустима стойност), а се търси минимум на доверителния интервал (вж. дефиниция за SRM в раздел 4.2.1 стр. 29).


#### 4.1 Теоретични основи на невронните мрежи.

Основното предназначение на невронните мрежи е да се моделира (наподобява) по програмен път или апаратно поведението на биологични системи при обработка на постъпващите от различни сензори данни. На практика те са реализация на теорията за разпределена и паралелна обработка на информация. Те се състоят от множество еднотипни обработващи елементи, които обменят помежду си едностранни сигнали и са свързани помежду си посредством връзки, притежаващи определен тегловен коефициент. Независимо от конкретно решаваната задача невронните мрежи се характеризират със следните особености:

- сложността на системата се обуславя не от сложността на изграждащите я елементи, а от сложността на връзките между тях;
- цялостното поведение на системата се формира от взаимодействието между много елементи, всеки от които може да активира или подтиска останалите, като по този начин се формира глобалното поведение на системата;
- едно от доминиращите свойства на поведението на невронната мрежа е стремеж към едно от нейните устойчиви статични или динамични състояния (в зависимост от свързването на изграждащите елементи);
- елементите на невронната мрежа не обменят кодове или символи помежду си, а си взаимодействат посредством активиране или подтискане (Уоссерман, 1992).

##### 4.1.1 Основни параметри и характеристики на НМ. Начини за формиране на мрежови топологии.

На Фигура 15 е представена примерна структура на напълно свързана НМ обучавана по правилото на обратното разпространение на грешката, която ще служи за илюстрация на привежданите по-долу разсъждения. Основните характеристики на тази НМ са: множеството еднотипни обработващи елементи<sup>28</sup>; състояние на активация  $a(t)$  за всеки елемент определящ неговия изход; връзката между елементите  $i$  и  $j$  определяна от тегловния коефициент  $w_{ij}$ ; правило за разпространение определящо ефективната стойност на входната величина от вход  $i_i$ ; активационна функция  $F_i$  (показани графично на Фигура 16), определяща новото ниво на активиране; допълнително отместване за елемента  $\theta$ .




Фигура 15 Примерна реализация на НМ обучавана по правилото на обратното разпространение

В зависимост от начина на свързване на невроните в мрежата и посоката на разпространение на сигналите в нея се разглеждат следните топологии невронни мрежи:

<sup>28</sup> Нарични често неврони.

еднопосочни мрежи и рекурентни мрежи. При първия тип потокът данни е от входните елементи към изходните без наличие обратни връзки т.е. няма връзка между изход от неврон към вход на неврони от същия или предходен слой (напр. персептрони, ADALINE). Докато рекурентните НМ притежават обратни връзки между невроните и менно те са факторът, който гарантира нейното обучение.



Фигура 16 Примерни често използвани активационни функции за елементите изграждащи НМ

#### 4.1.2 Активност и пластичност на НМ. Импулс и симетрия при НМ. Глобални и локални екстремуми.

Както бе отбелязано по-горе НМ се представя като мрежа от неврони с връзки между тях реализирани от тегловни коефициенти, които пропускат сигнал (активиращ или подтискащ) само в едната посока. Единствен изход на отделния неврон е неговата импулсна активност, зависеща от сигналите постъпващи от свързаните с него неврони. Ако приемем, че активността на  $i$ -тият елемент се описва еднозначно със скаларната величина  $a_i(t)$ , то активността на цялата система се описва с вектор  $A(t)=\{a_i(t)\}, i=1...N$  като времето е непрекъснато или дискретно (в този случай стъпката е единица).

Степента на взаимодействие между елементите вътре в мрежата се определя от матрицата на тегловните коефициенти  $W$  на НМ, чиито елементи  $w_{ij}$  определят величината и знака на връзката от елемент  $j$  към елемент  $i$  (при  $w_{ij}<0$  имаме подтискане на неврона, към който е насочена, докато при  $w_{ij}>0$  активирание). Активността на отделен неврон в даден момент от време  $t$  се определя от свързаните с него неврони и се представя с формулата :

$$a_i(t)=F_i[i(t)]= F_i\left\{ \sum_{j=1}^n w_{ij} \cdot a_j(t) + \theta \right\} \quad [9]$$

В най-често разглеждания случай функцията  $F_i$  е сигмоид (вж. Фигура 16 а).

В качеството на пластични елементи в теорията на невронните мрежи се разглеждат или целите неврони или само синаптическите връзки между тях. Техният брой определя възможностите и сложността на поведение на невронната мрежа. Очевидно е, че броят на връзките между невроните е далеч по-голям от броя на самите неврони и поради този факт се използват мрежи с пластични неврони (променливи тегловни коефициенти  $w_{ij}$ ).

Синаптичната пластичност се проявява в следните форми: поява на нова връзка, промяна на съществуваща и изчезване на съществуваща. Основна тип пластичност е промяната на съществуваща, тъй като другите две са нейни частни случаи. Приема се, че промяната в тегловният коефициент  $\delta w_{ij}$  (пластичността) зависи само от текущата стойност и текущата стойност на активността, което води до обобщеното правило на Хеб  $\delta w_{ij}=F\{w_{ij}(t), t_i(t), a_i(t), a_j(t), c_i(t)\}$ , където  $t_i(t)$  е обучаващ сигнал постъпващ към неврона,  $a_i(t)$  и  $a_j(t)$  са активностите на пре- и постсинаптичните неврони,  $c_i(t)$  е сигнал разрешаващ или забраняващ промяната на коефициента.



В зависимост от това дали съответния неврон е входно/изходен или принадлежи на скрит (вътрешен) слой правилото за промяна на тегловните коефициенти има различна форма. За двуслойна мрежа (входове и изходи) то има вида:

$$\delta_i \cdot w_{ij} = \varepsilon \cdot \delta_i \cdot a_j(t) \quad [11]$$

където  $\varepsilon$  е константа, задаваща скоростта на обучение, която се получава по формулата  $\delta_i = t_i - a_i$  и мрежата търпи промени докато  $\delta_i$  не стане 0 или по-малко от зададена стойност. За мрежи при които има скрити слоеве правилото е същото, а изчисляването на  $\delta_i$  е по следната схема: за неврони от изходния слой се прилага формулата  $\delta_i = F'(i_i(t)) \cdot (t_i - a_i)$ , а за неврони от скритите слоеве  $\delta_i = F'(i_i(t)) \cdot \sum [\delta_k w_{ki}]$ ,  $\delta_k$  е грешката за  $k$ -тия неврон от следващия слой.

*Необходимо е да се вземе предвид, че скоростта на обучение е пряко свързана с наличието на локални минимума по повърхнината на грешката която е равна на разликата |желан изход – изход от модела|, и с помощта на прилагания импулс за тяхното преодоляване, който е заложен за етап „обучение на модел“ следва да се достигне до глобален минимум, който да доведе до оптимален за конкретната задача модел реализиран от НМ (вж. Фигура 17).*


Следва да се отбележи, че в процеса на промяна на тегловните коефициенти  $w_{ij}$  броят итерации (наричани също така и епохи), които е необходимо да бъдат извършени за достигане на стабилно състояние на мрежата, е пропорционален на сложността  $\eta$ <sup>29</sup>. С оглед ускоряване на този процес и увеличаване на устойчивостта на НМ е целесъобразно към корекцията  $\delta_i$  да се добави още един член, който е пропорционален на стойността на предходното изменение. Тогава правилото се за модификация на всеки един тегловен коефициент свързващ два неврона се задава с  $\Delta w_{ij}(t) = \varepsilon \cdot \delta_i \cdot a_j(t) + \alpha \cdot \Delta w_{ij}(t-1)$ , където  $\alpha \sim 0.9$  се нарича коефициент на импулса или моментум, който осигурява движение по най-ниските части на повърхнината формирана от стойностите на функцията на грешката (вж. Фигура 17).

Характерна особеност за реализиране на бързо и успешно обучение на НМ е присвояването на начални стойности на матрицата с тегловни коефициенти  $w_{ij}$ . Много често на този етап се прилага следното правило – ако е необходимо тегловните коефициенти в края на процеса след промяна на тегловните коефициенти те да имат различни стойности, то и в началото те трябва да са различни т.е. матрицата с тегловни коефициенти да не е симетрична.

В процеса на корекция на тегловните коефициенти на НМ, целящи обучението  $\eta$ , на практика се реализира градиентно спускане по повърхността на грешката (вж. Фигура 17). Тъй като тази повърхност има ясно изразени хълмове и долини сериозен проблем е достигането до най-дълбоката долина т.е. намирането на глобален минимум осигуряващ стабилност на достигнатото от НМ състояние. От друга страна установяването в локален минимум води до неоптимално решение на проблема за обучението на НМ, което при конкретната реализация на модел с НМ за тематична класификация на данни от ДИ крайният резултат е висок процент на погрешно класифицирани МКСД.

Съществуват различни подходи при преодоляване на този проблем (локален минимум) – увеличаване и промяна знака на отместванията  $\theta$  и на тегловните коефициенти  $w_{ij}$ ; комбиниран метод обединяващ градиентното спускане и статистически методи. Като по-успешен, в смисъл на осигуряване на по-висока надеждност, се е наложил вторият подход. При него се прилага следният алгоритъм на работа: в началото на тегловните коефициенти  $w_{ij}(t)$  се присвояват случайни, различни стойности; след това на  $\Delta w_{ij}(t)$  се присвояват случайни, високи стойности и се осъществяват корекции само на тези тегловни коефициенти минимизиращи грешката; на следващите етапи стойностите на  $\Delta w_{ij}(t)$  постепенно се намаляват. Този алгоритъм за работа в голяма част от случаите води до успешно достигане на глобален минимум, запазвайки висока скорост в процеса на създаване на модела.

<sup>29</sup> Брой обработващи елементи и брой на слоевете на мрежата.



Фигура 17 Повърхност на грешката и метод за намиране на глобален минимум в процеса на обучение (Кестан,2001)

#### 4.1.3 Обучение на НМ. Подходи и специфика при избор на обучаващо множество. Функция на грешката и повърхност на решенията.

Възможността на невронната мрежа да бъде обучена да реагира еднозначно на еднотипни входни въздействия, подобно на своя биологичен аналог, е основното ѝ достойнство в сравнение с други методи за описание на зависимости между две множества. Методите, по които се реализира промяната на тегловните коефициенти на невронната мрежа са: с предварително формирана обучаваща извадка (класификация с обучение чрез НМ) и самообучение на базата на правила и налични данни (класификация без обучение с НМ).

Вторият метод от споменатите по-горе за създаване на модел на НМ използва наличните във входните данни структури за формиране на кълъстери използвайки статистически разграничими особености във входните данни. Неговата програмна реализация е посредством т.нар. самоорганизиращи се мрежи (self-organizing maps – SOM), позволяваща двумерно представяне на връзките и взаимодействията налични в многомерни данни посредством нелинейно преобразуване (Li,2005). Тъй като този тип НМ не отговарят на поставените в дисертацията задачи те са споменати за яснота на изложението и няма да бъдат предмет на допълнително изследване.

При метод, създаващ модел на НМ, която следва да реализира класификация с обучение ключов момент е промяната на тегловните коефициенти, която се извършва докато се достигне до предварително зададен праг на съответствие (допустима грешка) между генерирания от модела резултат и желан изход задаван от потребителя. Конкретно за решаване на задачи за класификация на МКСД от ДИ в търсени информационни класове по-широко приложение е намерил методът за класификация с обучение с НМ, прилагаща правилото за обратно разпространение на грешката при обучение и използващ като структура на мрежата двуслоен перцептрон без обратни връзки<sup>30</sup>. Изборът на този тип мрежа и в настоящата дисертация се обуславя от факта, че структура на НМ, имаща един слой неврони с нелинейна активационна функция и един слой с линейни изходни неврони успешно апроксимира произволна непрекъсната функция като необходимо условие е размерът на обучаващата извадка да не е ограничен (Hornik,1989). От друга страна теоремата за конвергенцията (Kroese,1993) гарантира, че след определено време, което е по-малко от безкрайност, тегловните коефициенти свързващи обработващите елементи ще достигнат стабилни стойности, което означава, че мрежата е в състояние да апроксимира със зададена точност функционалната зависимост (входни данни;желан изход).

<sup>30</sup> За подробно описание относно използване на НМ при обработка на изображения получени от различни източници вж. (Egmont-Petersen, 2002).

#### 4.1.4 Обучение на НМ по правило с обратно разпространение на грешката.

Обучението на НМ с обратно разпространение на грешката се състои в минимизация на сумарната грешка от разсъгласуването между желан и реален изход от модела посредством промяна на стойностите в матрицата на тегловните коефициенти  $w_{ij}$  (вж. Фигура 15). Ако  $E$  представлява общата средноквадратична грешка получена след подаване на входа на невронната мрежа на всички комбинации вход/изход от обучаващото множество, то уравнението, с което тя се задава има следния вид:

$$E = \sum_{p=1}^n E^p = \frac{1}{2} \sum_{p=1}^n (t_{pi} - a_{pi})^2 \quad [12]$$

където:  $p$  е множеството от обекти;  $i$  множеството от изходни елементи;  $t_{pi}$  е желания, а  $a_{pi}$  реалния изход, при подаване на входа на  $p$ -тото входно въздействие. В този случай за да се осигури намаляване стойността на сумарното разсъгласуване промяната на тегловния коефициент  $w_{ij}$  се задава съгласно обобщеното делта правило:  $\Delta w_{ij}(t) = \varepsilon \cdot \delta_i \cdot a_j(t)$ .

При метода прилагаш обратно разпространение на грешката промяната на  $\delta_i$  е итеративен процес започващ от изходните елементи на невронната мрежа и се изчислява по следните формули –  $\delta_i = F'_i(i_i(t)) \cdot (t_i - a_i)$  за изходните неврони и  $\delta_i = F'_i(i_i(t)) \cdot \sum (\delta_k \cdot w_{ki})$  за неврони от скритите слоеве, а  $\delta_k$  е грешката за  $k$ -тия неврон от следващия слой.

Този метод за обучение включва две фази:

- по време на първата постъпилият входен вектор се разпространява през невронната мрежа за да се изчислят стойностите на  $a_{pj}$  за всеки неврон и да се получи резултантен вектор, който сравнява с желания изход  $t_{pi}$  за да се определи  $\delta_i$  за изходните неврони;
- по време на втората сигналът, отговарящ на грешката преминава обратно през невронната мрежа като се изчисляват новите стойности на  $\delta_i$ .

При завършване на тези две фази (често наричани и епохи) се изчислява промяната на стойността по обобщено делта правило за всеки тегловен коефициент  $w_{ij}$ .

По своята същност методът за обучение на невронна мрежа прилагаш правилото за обратно разпространение на грешката реализира движение по повърхността на грешката  $E$  при разсъгласуване посредством спускане по нейния градиент (вж. Фигура 17). При еднослойна структура на невронната мрежа има само един минимум, но ако структурата на невронната мрежа включва повече от един слой повърхността на грешката  $E$  като правило има повече от един минимум. В този случай някои от минимумите от повърхността на грешката да удовлетворяват условието  $E \sim 0$ , но е възможно прилагайки метода на градиентното спускане достигането на локален, но и не оптималния минимум.

В (Roli, 2001) се подчертава, че един от основните проблеми при използване на НМ за класификация е подборът на подходяща структура на мрежата и пак там е показано, че мрежа с един скрит слой предоставя много добри крайни резултати. При конкретната реализация на етап „създаване на модел“ с НМ по метода с обратно разпространение на грешката е възможно да бъдат приложени и негови модификации ускоряващи неговото изпълнение (напр. Matrix Back Propagation (Anguita, 1993), (Soliman, 2007)).

Приложения подход използващ невронна мрежа за класификация на МКСИ има следните две предимства – класификация към един и същи клъстер на несвързани подобласти от пространството на признаците и работа в многомерно пространство на признаците с размерност по-висока от тази, с която би могло да се ползва от статистическите методи.

#### 4.1.5 Пример за приложение на НМ при обработка на многоканални изображения – филтрация на МКСД.


В съвременните системи за дистанционни изследвания след получаване на електрическия сигнал, който съответства на измерената в даден момент яркост на природните образувания в един или повече спектрални канала е необходимо от него да бъде отстранен шумът, който се регистрира заедно с него. С помощта на НМ е възможно да се извърши двумерна филтрация,

която се реализира от невронна мрежа с един скрит слой, в която нелинейните елементи от скрития слой имат активационна функция  $\sin(x)$  (вж. Фигура 18). Нейното функциониране може да бъде обяснено, ако разгледаме разлагането на произволна функция в ред на Фурие:

$$f(x) = \sum_0^{\infty} \{a_i \cdot \cos(i \cdot x) + b_i \cdot \sin(i \cdot x)\} \quad \text{или} \quad \text{неговия} \quad \text{еквивалентен} \quad \text{запис}$$

$$f(x) = a_0 + \sum_0^{\infty} c_i \cdot \left\{ \sin(i \cdot x + \theta_i) \right\}, \quad \text{където} \quad c_i = \sqrt{a_i^2 + b_i^2} \quad \text{е амплитудата, а фазата е} \quad \theta_i = \arctan\left(\frac{b_i}{a_i}\right)$$

(Rojas, 1996).



Фигура 18 Реализация на филтрация с функция на Фурие от НМ.

Последната формула може да се разглежда като еднопосочна мрежа с единичен вход  $x$ , скрити слоеве с активационна функция  $\sin(x)$  и изходен неврон. В този случай членът  $d_0$  съответства на отместване за изходния елемент,  $w_i$  на тегловните коефициенти свързващи скрития и изходния слой, фазата  $\theta_i$  е еквивалент на отместванията в скрития слой и броят  $i$  е равен на тегловните коефициенти свързващи входния и скрития слоеве.

## 4.2 Теоретични основи на метода на опорните вектори

Нови възможности пред методите за разпознаване на образи, в конкретния случай представени като информационни класове, съответстващи на класове земно покритие, предостави развитието на теорията на опорните вектори (Support Vector Machines – SVM) (Vapnik, 1971). Тя стои в основата на разработения впоследствие метод на опорните вектори (МОВ) за класификация на данни. Негово основно предимство пред други методи прилагани за решаване на подобни задачи е, че позволяват по-добра разделимост на класовете от предварително избрана функция, най-често нелинейна, посредством увеличаване размерността на пространството на ХП. Друга важна характеристика на моделите изградени по този метод е по-добрата им способност за обобщаване в процеса на разпознаване (Thenkabail, 2016), тъй като позволяват да бъдат взети под внимание параметри, които статистическите методи не отчитат.

Основната идея заложена в МОВ е да се извърши разделяне на класовете формирани от входните данни с линейна функция, използваща т.нар. опорни вектори, които представляват онези точки от данните, които са разположени най-близо до линията или повърхнината разделяща множествата и които като правило е най-трудно да бъдат коректно класифицирани<sup>31</sup>. Ако линейно разделяне на  $n$ -мерните входни вектори  $X|x_1, \dots, x_n|$  от пространството на ХП не е възможно, то тогава те се трансформират във вектори  $Z|z_1, \dots, z_k|$  в пространство на характеризиращи признаци  $Z$ , което е с по-висока размерност, където такова разделяне е възможно. Формализираното представяне на това преобразуване има следния вид:  $(y_1; x_1), \dots, (y_n; x_n) \Rightarrow (y_1; z_1), \dots, (y_n; z_k)$  и на базата на което  $y$  може да се представи с


<sup>31</sup> За тях е в сила и твърдението, че ако една или повече от тях отпаднат разположението на разделящата хиперравнина се променя.

помощта на линейна функция  $y = (w^*z) + b$ , където  $w^*z$  е векторно произведение, а  $b$  е отместване (вж. Фигура 19). Два са проблемите, които следва да се решат при тази реализацията на тази трансформация:

- какви свойства трябва да притежава линейната функция, тъй че най-добре да апроксимира желаната функция (регресия) или да извърши разделянето (класификация);
- по какъв начин се да формира хиперравнината в пространството с по-висока размерност.

#### 4.2.1 Минимизиране на структурния риск и VC размерност

За да се разреши първият проблем поставен по-горе е въведен едно нов подход наречен минимизиране на структурния риск (MCP) (structural risk minimization – SRM) (Vapnik, 1995). Посредством него се оценява адекватността на формирания модел на данните отнесена към спецификата на самите данни посредством минимизация горната граница на получаващата от модела грешка при обобщаване. Тази граница на функцията при MCP се определя от два члена – емпиричния риск и функцията на VC-размерността, която съответства на сложността на пространството на хипотезите – като и за двата члена на функцията (вж. формула [13]) се търси минимум (Blonda, 2002).



Фигура 19 Разделимост в пространството на характеризиращите признаци посредством МОВ.

Разбирането на този подход има ключово значение при конкретно приложение на метода опорните вектори, тъй като без него методът не може да бъде обоснован теоретично и поради тази причина ще бъде разгледан в следващите параграфи.

Нека приемем, че грешката при обобщаване е сума от грешката при апроксимация на реалната функция и грешката от оценка на стойността. В този случай е необходимо да се намери такава функция, която минимизира риска при подмяна на реалната стойност с такава получена при обобщението. Това допускане има следното представяне:

$$R[f] = \int_{x,y} (y - f(x))^2 P(x, y) dx dy \quad [13]$$

където  $P(x, y)$  е неизвестно разпределение за данните, за което се допуска, че данните са получени в произволен ред и имат еднакво разпределение.

Възможно е да бъде намерена апроксимация на търсената функция разделяща надеждно данните, прилагайки принципа за минимизиране на емпиричния риск (ERM) в съответствие с формулата:

$$R_{emp}[f] = \frac{1}{l} \sum_{i=1}^l (y - f(x_i))^2 \quad [14]$$

която минимизира емпиричния риск, който се дефинира съгласно:

$$\hat{f}_{n,l}(x) = \arg \min_{f \in H_n} R_{emp}[f] \quad [15]$$

Горната формулировка има смисъл само ако е в сила условието:

$$\lim_{l \rightarrow \infty} R_{emp}[f] = R[f] \quad [16]$$

което условие съгласно закона за големите числа е вярно и също така трябва да удовлетворява :

$$\lim_{l \rightarrow \infty} \min_{f \in H_n} R_{emp}[f] = \min_{f \in H_n} R[f] \quad [17]$$

Последното условие е по-малко интуитивно и е валидно само ако  $H_n$  е достатъчно малко.

Следва да се вземе пред вид, че принципа на минимизация на структурния риск създава структура, в която основно място заема VC размерността. По дефиниция тя е скалярна величина, равна на максималния брой точки, които могат да бъдат разделени по всички възможни начини от конкретно избрано множество функции  $f$  (Vapnik, 1971), а ако обучението може да раздели произволен брой точки се приема, че VC размерността е безкрайност.

На практика MCP се свежда до намиране решение на :

$$\min_{S_n} \left[ R_{emp}[f] + \sqrt{\frac{h \cdot (\ln \frac{2l}{h} + 1) - \ln(\frac{\delta}{4})}{l}} \right] \quad [18]$$

където  $h$  е цяло число наречено размерност на Вапник-Червоненкис и дава представа за възможностите на избраният набор от функции  $f(x)$  да класифицира и да обобщава след обучение с конкретен набор данни. Необходимо е да се отбележи, че при размерност  $h$  ( $h \neq \infty$ ) съществува поне едно множество от  $h$  точки, които могат да бъдат разделени, но в общия случай не е се гарантира, че всяко множество от  $h$  точки е разделяемо по този начин (за доказателство вж. (Burges, 1998)).

Съгласно показаното на Фигура 19 каноничният запис на разделящата хиперравнина е:

$$y_i[(w \cdot x_i) + b] \geq 1, \quad i = 1, \dots, l \quad [19]$$

#### 4.2.2 Класификация с нелинейни функции по МОВ

Разгледаната дотук теоретична постановка е директно приложима при линейно разделями класове, но ако погледнем отново Фигура 11 се вижда, че за МКСД получени при реален експеримент от ДИ, които са линейно неразделими следва да бъде потърсено допълнение към решението предложено от по-горната формулировка. Такова решение е предложено в (Cortes, 1995), при което се въвежда набор от положителни променливи  $\xi_i$ , съответстващи на грешката при класификация ( $\xi_i=1$  съответства на гранична точка,  $\xi_i>1$  погрешно класифицирана точка). Намирането на оптимална разделяща равнина с свежда до минимизиране на грешката при класификация и на VC размерността на класификатора, и тогава формула [19] добива вида:

$$y_i[(w \cdot x_i) + b] \geq 1 - \xi_i, \quad i = 1, \dots, l \quad [20]$$


а оптималната хиперравнина се задава от вектора  $w$ , който минимизира следния функционал:

$$\Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad [21]$$


в който стойността на константата  $C$  е регуляризиращ параметър, който задава формата на дискриминантната функция и съответно разделящата хиперравнина, ако данните са неразделими, а променливите  $\xi_i$  отчитат влиянието на некоректно класифицираните данни (Dalponte, 2009). Константата  $C$  от формула [21] се задава от потребителя на етап „обучение на модел“ и е предмет на оптимизация при създаване на всеки един конкретен модел, прилагащ МОВ.

В случай, че данните в избрано пространството на ХП са линейно неразделими или получаващата грешка при линейно разделяне е неприемлива се извършва трансформация на данните от пространството на ХП в пространство с по-висока размерност, където е възможно тяхното разделяне с линейна функция, но представено в пространството на ХП полученият модел реализира разделянето на данните с нелинейна функция (вж. Фигура 20).

Примери за  
линейноразделими и линейнонеразделими  
класове



Трансформация с функционални ядра



Фигура 20 Линейно неразделим случай и преминаване към пространство с по-висока размерност.

Това преобразуване на пространството на входните данни е възможно с помощта на т.нар. трансформация с функционални ядра (в литературата е позната като kernel trick), която се реализира посредством една от функциите представени в Таблица 2. При реализация на функционално ядро чрез линейна функция не се извършва преобразуване на изходното пространство на ХП към пространство с по-висока размерност, но за ядра с ФРБ и полином такава трансформация се извършва. Ако разгледаме ядро реализирано от функция полином от втора степен разделящите равнини в изходното пространство са конични (елиптични или хиперболични), което потвърждава теоретичната постановка на МОВ, че полученото решение е оптимално (Yaman,2012) т.е. достига се до глобален минимум по отношение на грешката.

линейна	$K(x_i, x_j) = x_i^T x_j$
полином	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^\alpha$
функция с радиален базис (ФРБ)	$K(x_i, x_j) = (-\gamma \ x_i - x_j\ ^\alpha), \gamma > 0$
сигмоид	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Таблица 2 Функционални ядра използвани за класификация на данни по МОВ

Един недостатък на МОВ, е че при размер на входното пространство на ХП  $n$  след трансформация с функционално ядро новото пространство на ХП е  $n^2$ , което рефлектира върху увеличаване обема необходима памет и на времето необходимо за получаване на дискриминантните функции за модела при програмна реализация на този метод (Ben-Nur,2010).

При така формулираната постановка при МОВ се избягва и проблемът възникващ от по-високата размерност на новосформираното пространство на трансформираните входни данни, което от своя страна изисква експоненциално нарастващ брой входни данни за обучение на модела (Oommen, 2008). Следва да бъде изтъкнато и още едно предимство на МОВ реализиран с помощта на функционални ядра – този метод се влияе в по-малка степен от ефекта на Хю (Plaza, 2009). От изложеното по-горе може да бъде направен изводът, че функционалните ядра предоставят гъвкавост и надеждност при програмна реализация на МОВ насочена към класификация на МКСД.

Особеностите на разгледаните в тази глава нелинейни методи за обработка на МКСД от ДИ, прилагачи НМ и МОВ, са:

1. базирани на непрекъснато развиващи се теоретични постижения, което води до предпочитането на този тип модели пред статистическия подход с оглед повишаване на крайната точност;
2. попадат в категорията на непараметричните методи (не предполагат нормално разпределение), които могат да се прилагат в пространство на ХП с висока размерност без да изпитват „ефекта на Хю“ и са по-неподатливи на преобучаване;
3. за моделите с НМ най-важна е топологията на мрежата и стойностите на тегловните коефициенти, от които зависи достигането до оптимален модел;
4. на етап „създаване на модел“ с НМ достигането до глобален минимум в повърхнината на грешката се постига с подходящи начални параметри за този етап;

5. за моделите по МОВ разделянето на данните се реализира от линия или равнина независимо от трансформациите, на които се подлага пространството на ХП и неговата размерност;
6. независимо от приложената стратегия за достигане до оптимален модел за класификация с НМ и по МОВ основно предимство се предоставя на способността на изградения модел за обобщаване, а не фокусират изключително върху точното възпроизвеждане на данните от обучаващата извадка.

## **Глава 5. Проведени експерименти за създаване на модели, прилагачи нелинейни функции за тематична класификация на МКСД**

### **5.1 Методика за извличане на единични спектри от МКСИ**

За да бъдат проведени планираните експерименти за тематична класификация на обекти от земната повърхност посредством на нелинейни методи, бе необходимо предварително да се подготвят данни в два формата – растерен и векторен. Основен източник на спектрална информация са растерни МКСИ, от които, съгласно описаната в раздел 3.3.1 последователност, се получават стойностите на отражение за изследваните обекти от повърхността на Земята. От тези данни се формира пространството на ХП за спектралните класове, които бяха използвани за достигане до съответстващите им информационни класове. Векторни данни от точков тип бяха използвани за прецизно извличане (в рамките на единичен пиксел) на стойностите на DN от растерните изображения като по този начин се гарантира, че информационните класове, в които се извършва класификацията са подбрани коректно. Освен споменатите използвани бяха и векторни данни от тип полигон на етапи „обучение и валидация на модел“, както и на етап „създаване на тематично изображение“. Векторните данни използвани на тези етапи бяха приети за предварително валидирани, тъй като те представляват подмножество полигони от проект КЗП за години 2000 и 2006 (Stoimenov, 2008).

*Растерни данни* Растерните данни, от които са взети стойностите за DN използвани при експериментите, са от две сцени от МКСА „Тематичен картограф“ (Thematic Mapper) разположен на борда на сателита Ландсат 5 от дати 09.10.1999г. и 04.10.2006г. От всяка една сцена беше извлечено по едно подизображение с размери 1973 колони и 1819 реда в шест отделни растерни файла, съответстващи на разглежданите спектрални интервали<sup>32</sup>, които обхващат Панагюрския руден район (Strashimirov, 2002), а координатите на подизображенията са посочени в Таблица 3. След това шестте изображения с растерни данни бяха подложени на описаните в раздел 3.3.1 процедури за трансформация, целящи представянето им в ТоА.


	географски координати	
	ширина	дължина
СЗ	42.973	23.874
СИ	42.973	24.623
ЮИ	42.307	24.623
ЮЗ	42.307	23.874

Таблица 3 Координати на ъгловите точки на изследвания район

*Векторни данни* Векторните данни включващи полигоните на изследваните класове в избрания район за изследване са подмножество от крайния продукт на проекти КЗП 2000 и 2006 предоставяни от Изпълнителна агенция по околна среда (вж. Фигура 21).


<sup>32</sup> При проведените експерименти топлинния и панхроматичния канали не са използвани





Фигура 21 Район на изследване и класове земно покритие съгласно класификация по проект КЗП.

Графично данните за броя и площта на полигоните от района са представени на Фигура 22, а пълното им описание е представено в Приложение 1. За изследвания район също така бе създадена и равномерна мрежа записана в отделен векторен файл от точков тип, отговаряща на ПРС на растерните данни 30м, която бе използвана за формиране на множествата данни използвани на етапи „обучение на модел“ и „валидация на модел“.



Фигура 22 Брой обекти и обща площ на полигони в района на изследване съгласно краен продукт на проект КЗП 2006”

Поради малкият размер на някои от полигоните за обучение и валидация се наложи те да бъдат присъединени към класове, които са спектрално сходни с тях с цел повишаване на точността при класификация на пълните обеми данни (вж. раздел 3.2). Това доведе до формиране на общо 17 информационни класа, с които впоследствие бяха извършени експериментите за създаване и оценка качеството на моделите с НМ и по МОВ, както и на етапа на класификация на пълния обем данни.

Номер по ред	Номер на клас по КЗП	Брой обекти	Площ в хектари	Брой пиксели
	112	3	3470.34	34703
	121	5	181.95	1819
	131	2	988.83	9888
	132	2	534.52	5345
	211	4	3237.79	32377
	222	2	178.14	1781


Номер по ред	Номер на клас по КЗП	Брой обекти	Площ в хектари	Брой пиксели
	231	3	486.50	4864
	242	3	1101.36	11013
	243	2	1479.99	14799
	311	2	921.51	9215
	312	2	1206.48	12064
	313	3	1476.90	14769
	321	3	9450.37	94503
	322	2	261.09	2610
	324	2	174.29	1742
	333	3	165.21	1652
	512	3	94.02	940

Таблица 4 Брой на обектите и техните площи използвани етап „създаване на модел“ (номенклатурата е съгласно възприетата по проект КЗП).

Проведените експерименти за създаване на модели с НМ и по МОВ са от близки дати в рамките на един и същи сезон с цел да се осигури съпоставимост между резултатите след създаване на моделите и последващата класификация на пълния обем данни. Резултатите от прилагане на вече изградените модели за окончателната тематична класификация на пълните набори данни от двете години са записани в растерени файлове и са кодирани с 17 цвята, които съответстват на информационните класове.


Получаването на стойностите за ТоА за всеки един от класовете бе извършено в следната последователност:

1. За целия район на изследване беше създаден векторен точков слой със стъпка отговаряща на разделителната способност на основния набор растерни данни 30м;
2. Създадени бяха векторни слоеве с полигони (минимум два за клас), включващи извадките използвани за обучение и валидация на създавания модел. (вж. Фигура 23);




Фигура 23 Растерен слой с наложени върху него два полигона за обучаваща и валидираща извадки за клас 112 по номенклатурата на проект КЗП

3. За всеки един от класовете с цел отделяне на пикселите за обучаваща и тестова извадки беше извършено пресичане на векторните слоеве от стъпка 2 с векторния слой от стъпка 1 като по този начин беше създаден нов векторен точков слой, който съответства точно на пикселите от растерния слой, които да се използват етап „създаване на модел“ (вж. Фигура 24);



Фигура 24 Векторен слой с точки в центъра на пикселите от растерен слой

4. Следващата стъпка беше да се извлекат от двете МКСИ с помощта на вече създаденият точков векторен слой нов точков векторен слой съответстващ на извадките за обучение и валидация за всеки един от класовете, в чиято атрибутивна таблица са включени и растерните стойности съответстващи на спектралните канали (вж. Фигура 25);



Фигура 25 Точков векторен слой с атрибути DN стойности получени от един растерен слой, съответстващ на спектрален интервал

5. Така получения векторен слой беше записан във формат, който може да се импортира в електронна таблица (най-често CSV) или в програмен продукт за обработка на растерни изображения (например SHP);
6. След въвеждането в електронна таблица или в ГИС стойностите на DN бяха трансформирани в ToA и след това в стойности съответстващи на отражение.

Като предимство на подробно изложената по-горе методика за извличане на DN стойности от растерни данни може да бъде посочено, че тя позволява многократно използване на векторните слоеве за извличане на стойности за DN от всички набори растерни данни, които се отнасят за същия район и имат същата ПРС.

Основният набор програмни компоненти<sup>33</sup> използвани при експериментите за създаване на класифицираща процедура, прилагаща нелинейни модели се разпространяват като част от програмната среда OSGeo4W за геопространствено моделиране за потребители на Windows (OSGeo4W, 2015). Тяхното използване е възможно както в среда на геоинформационна система QGIS, така и като самостоятелен модули от команден ред<sup>34</sup>.

<sup>33</sup> Orfeo toolbox – ОТВ

<sup>34</sup> За необходимите условия за самостоятелно ползване на модулите вж. <http://trac.osgeo.org/osgeo4w/>

При използването на всеки един модул на етап „създаване на модел“ обучаващото множество се разделя на две извадки – едната използвана на етап „обучение на модел“, а другата за неговата кросвалидация. Размера на двете извадки е възможно да бъде задаван или като конкретни стойности, или да бъде използван максимален брой за всеки един от класовете. В резултат на извършената кросвалидация за формираната на етап „обучение на модел“ структура се получават стандартизирани оценки за неговата точност (напр. параметър *каппа* или средна точност), което дава първоначална представа неговото качество. Окончателна оценка за възможностите на модела се получава едва след като той бъде приложен върху пълния набор данни (етап „създаване на тематично изображение“) и като правило в този случай стойностите на оценките са по-ниски, което е следствие от невъзможността при обучението да бъдат включени всички възможни комбинации от входни параметри.

При използване на ОТВ в процеса на изследването е спазена следната последователност при работа с модулите, реализиращи създаване и прилагане на модели за класификация с нелинейни функции<sup>35</sup> – статистическа оценка на входните данни (текстов файл); формиране на обучаваща извадка и извадка за валидиране на получения модел за всеки клас (векторен файл); създаване на конкретен модел при зададени начални параметри (текстови файлове с параметрите на модела и матрица на грешката след кросвалидация); прилагане на формирания модел за класификация на всички данни налични в изображението (растерно изображение); оценка на точността на получените резултати към тестовите или други данни (текстови файлове с параметрите на модела и матрица на грешката).

За се получи представа за адекватността на получаваните резултати на стъпки 3 и 5 е необходимо да се формират матрици на грешката при класификация. На стъпка 3 тя се изчислява след като формираната на етап „обучение на модел“ структура извърши класификация върху МКСД предвидени за нейната кросвалидация. На стъпка 5 такава матрица се получава след като модела вече е извършил класификация върху пълния набор МКСД и резултатното тематично изображение се съпостави с референтно такова. От така формираните матрици на грешката е възможно да бъде изчислен коефициент  $\kappa$  (каппа) (Foody, 2002), който в рамките на тази дисертация ще се използва като основен критерий за оценка качеството на конкретно изградения модел, както и за качеството на крайните резултати. По дефиниция този коефициент отразява степента на съгласуваност между оценките получени при две независими наблюдения върху едни и същи данни, а една негова дефиниция от практиката е *“сравнение между причисляване към конкретен клас с причисляване към произволен клас”*. Неговите стойности са в интервала  $[0;1]$ , като 1 съответства на точно съвпадение на резултатите при двете наблюдения, 0 на липса на съвпадение.

В (Shao, 2012) се обсъжда влиянието на размера на обучаващата извадка върху крайната точност при класификация при създаване на модел по три различни алгоритъма (вж. Фигура 26) и направеният там извод е, че нейното увеличаване не е право пропорционално на точността, което бе взето под внимание при провеждането на експериментите за реализиране на целите на дисертацията и бе потвърден от получаваните резултати, което позволи намаляване броя на провежданите експерименти.

## 5.2 Програмни продукти, използвани при създаване на модели с невронни мрежи за класификация на МКСД


### 5.2.1 Програма *Neumapper*

Предназначението на този програмен продукт, реализиран с подкрепата на ЕКА и предоставен свободно ползване след регистрация на сайта на фирмата, която го е разработила<sup>36</sup>, има за основно предназначение попикселна класификация (*per pixel classification*) на МКСД от ДИ по метод с предварително обучение, използващ НМ. Той

<sup>35</sup> В скоби е указан типа (формата) на файла получен след изпълнението на дадената стъпка

<sup>36</sup> <http://www.geo-k.co/geo-k-profile/>

притежава следните качества – точност при класификация съпоставима с тази постигана чрез статистически методи; не е наложително познаване на статистическото разпределение на класовете в изходните данни; може да бъде приложен за класификация на данни от различни източници (т.е. от различни сензори и апаратурни комплекси).



Фигура 26 Промяна в оценката карра при нарастване размера на обучаващото множество.

### 5.2.2 Програмен компонент НМ като част от геоинформационна система QGIS

В процеса на използване на програмен компонент НМ от ОТВ за класификация на данни от ДИ следва да се отчита следната особеност – първо след серия от експерименти е необходимо да бъде установена структурата на мрежата (брой входни и изходни елементи, брой на елементите в скрития слой), които осигуряват максимално коректна класификация и едва след това се извършва самата настройка на останалите параметри на модела. Един от важните параметри, които е необходимо да бъдат указани при използване на този програмен компонент за изграждане и настройка на модел с НМ с обучение по правилото с обратно разпространение на грешката, са активационните функции за всеки един от обработващите елементи на мрежата (вж. Фигура 15), които определят в значителна степен качеството на получавания модел. В таблицата по-долу са показани наличните в този програмен компонент активационни функции, чиито параметри следва да бъдат променени за се достигне до оптимален модел с НМ.

Функция	Формула
Тъждественост	$f(x) = x$
Сигмоид	$f(x) = \beta * \frac{1 - e^{-\alpha x}}{1 + e^{-\alpha x}}$
Гaus функция с радиален базис (ФРБ)	$f(x) = \beta * e^{-\alpha * x}$

Таблица 5 Поддържани активационни функции за елементите на НМ

Като сериозно предимство на този програмен компонент следва да се изтъкне фактът, че позволява създаване на модел с НМ, която има повече от един скрит слой.

### 5.3 Програмни продукти, позволяващи прилагане на класификация на МКСД от ДИ по алгоритъм МОВ

Прилагането на МОВ за класификация на МКСД от ДИ придобива все по-широка популярност, тъй като притежава добрата способност за обобщаване при сравнително неголям брой обучаващи данни (Fauvel, 2006), (Thenkabail, 2016).

#### 5.3.1 Програмен компонент МОВ като част от геоинформационна система QGIS<sup>37</sup>

При разглежданата конкретна реализация на МОВ на разположение на потребителя са две възможности – libSVMи SVM – като и при двете реализации на МОВ могат да бъдат използвани показните в Таблица 6 функционални ядра. За получаване на модел по МОВ

<sup>37</sup> Освен ката модул от QGIS тази библиотека се ползва и като част от самостоятелната програма Monteverdi разпространявана от CNES

влияние върху крайните резултати оказват два коефициента –  $C$  и  $\gamma$  (Thenkabail, 2016). Първият определя начина, по който алгоритъмът ще третира данните, които попадат в погрешния клас след прокарване на разделящата равнина, докато коефициентът  $\gamma$  задава ширината на функцията с радиален базис и оказва влияние само ако се използва такъв тип ядро, което предполага емпиричното намиране на неговата оптимална стойност на етап „създаване на модел“.

Тип на функционалното ядро	Формула
линейно	$K(x,y)=x \bullet y = (x \bullet y)$
ядро полином	$K(x,y)=(\gamma*(x \bullet y)+coef_0)^{degree}$
функция с радиален базис	$K(x,y)=\exp(-\gamma* x \bullet y ^2)$
функция сигмоид	$K(x,y)=\tanh(\gamma*(x \bullet y)+coef_0)$

Таблица 6 Функционални ядра реализирани в ОТВ за МОВ по (Wagner, 2012)

### 5.3.2 Програмен компонент МОВ като част от програмен продукт Opticks

Този програмен компонент е реализиран като допълнение към програмен продукт Opticks<sup>38</sup>, но се поддържа само определени негови версии. Модулът, с който се формират обучаващите и данните за валидация е базиран на предложението от (Bruzzone, 2000) алгоритъм за автоматичен анализ на разликово изображение получено при класификация без обучение на мултитемпорални изображения.

В основата на цитирания алгоритъм стои разновидност на алгоритъма за класификация по метода на максималното правдоподобие прилагана при недостатъчен размер на обучаващата извадка наречен *максимизиране на очакването* (expectation maximization) (Do, 2008). Класификацията по метод МОВ се провежда от процедура, използваща алгоритъм *последователна оптимизация на минимума* (sequential minimal optimization), който декомпозира задачата на квадратичното програмиране с евристични методи и елиминира необходимостта от матрични изчисления.

## 5.4 Резултати от проведените експерименти

### 5.4.1 Експерименти за класификация на МКСД без обучение проведени по методи на К-средните и ИСОМАД

В рамките на изследването за да се придобие обща представа относно групирането на изследваните класове земно покритие в пространството на ХП формирано изключително от спектрални данни бяха проведени експерименти с два алгоритъма за клъстеризация – на К-средните и по ISODATA. И в двата случая бе заложено да се формират 22 класа (този брой бе избран тъй като отговаря на броя класове налични в района на изследване съгласно резултатите от проект КЗП 2006) и въпреки различните алгоритми на работа при двата цитирани метода параметрите, определящи начина на разделяне бяха подбрани по такъв начин, че да бъдат максимално близки (например и в двата случая размерът на представителната извадка бе зададен да е 10000, а броят итерации бе 1000). Целта на тези проведени експерименти беше да се установи колко от спектрално различимите класове са в съответствие с информационните класове за изследвания район съгласно класификацията по проект КЗП.

В Таблица 7 и в Таблица 8 са показани получените резултати от валидиране на получения модел в тестови обекти за всеки един от класовете по КЗП след прилагане на класификация за пълния обем данни по двата метода. Както е видно от таблиците по-долу в тестовите обекти при метод на К-средните спектрално присъстват 8 класа, а при метод ИСОМАД класовете са 9, което показва наличието на множество пиксели от тип “смесен клас”. В таблиците също така са показани двата най-често срещани спектрални класа във всеки тестов обект (Kmeans1/Kmeans2 и съответно ISODATA1/ISODATA2).

<sup>38</sup> <http://opticks.org/confluence/display/opticks/Welcome+To+Opticks>


Class CLC	Class Kmeans1	number	as % of total	Class Kmeans2	number	as % of total
322	3	258	22,42%	5	225	19,55%
324	3	510	21,88%	7	502	21,54%
121	4	138	46,78%	13	74	25,08%
132	4	1212	40,32%	13	441	14,67%
333	4	597	59,70%	19	182	18,20%
311	5	282	47,00%	15	98	16,33%
312	5	502	30,26%	15	466	28,09%
313	5	494	35,51%	15	394	28,32%
131	6	682	28,57%	4	607	25,43%
512	6	382	87,41%	16	35	8,01%
142	7	254	20,70%	3	209	17,03%
222	7	381	23,27%	3	319	19,49%
242	7	382	25,81%	10	198	13,38%
243	7	263	17,45%	3	220	14,60%
112	10	1009	37,69%	7	396	14,79%
122	10	96	31,07%	16	72	23,30%
231	10	21	42,00%	7	19	38,00%
211	11	553	22,83%	10	531	21,92%
321	19	496	42,21%	18	129	10,98%

Таблица 7 Клъстеризация по спектрални класове- метод на К-средните; спектрално различни 8 класа.

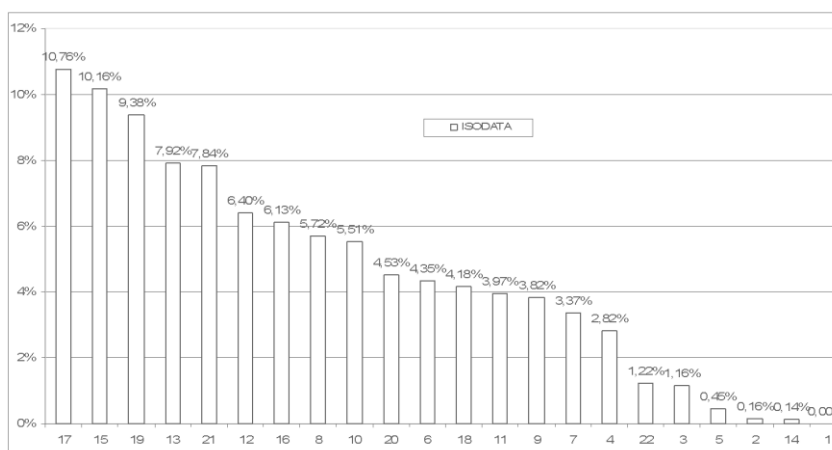
Class CLC	Class ISODATA1	number	as % of total	Class ISODATA2	number	as % of total
121	3	59	20,00%	5	50	16,95%
132	3	677	22,52%	4	465	15,47%
333	3	405	40,50%	4	227	22,70%
321	7	465	39,57%	9	200	17,02%
211	8	713	29,44%	10	569	23,49%
112	10	972	36,31%	16	401	14,98%
122	10	98	31,72%	18	66	21,36%
142	12	234	19,07%	16	221	18,01%
243	12	283	18,78%	16	266	17,65%
131	14	673	28,19%	5	496	20,78%
222	16	445	27,18%	12	273	16,68%
231	16	41	82,00%	10	6	12,00%
242	16	390	26,35%	12	313	21,15%
324	16	606	26,00%	12	419	17,98%
322	18	316	27,45%	12	160	13,90%
312	19	433	26,10%	17	381	22,97%
313	19	418	30,05%	17	383	27,53%
311	21	201	33,50%	19	145	24,17%
512	22	351	80,32%	20	32	7,32%

Таблица 8 Клъстеризация по спектрални класове- метод ISODATA; спектрално различни 9 класа.

На Фигура 27 и Фигура 28 са показани резултатите след прилагане на класификация без обучение върху целия набор данни по двата метода – К-средните и ИСОМАД. Получените тук резултати, които представляват процент от целия обем класифицирани данни, ще бъдат използвани в процеса на сравнение между тях и резултатите получавани по методите за класификация с обучение, използващ нелинейни функции.



Фигура 27 Разпределение на класовете в цялото изображение след класификация по метод K-средните



Фигура 28 Разпределение на класовете в цялото изображение след класификация по метод ISODATA

От изложените в горните таблици и фигури резултати може да се направи и следният извод – наличието на пиксели от тип “смесен клас” в обектите от обучаващата извадка е предпоставка да се очакват невисоки стойности за точността при класификация по метод с предварително обучение – НМ и МОВ. От друга страна тази особеност ще позволи да бъде проверена способността за обобщаване на всеки един от създаваните модели с НМ и по МОВ базирани на нелинейни методи.

#### 5.4.2 Методика за съвместно прилагане на статистически подход и класифицираща процедура използваща НМ.

Един добър подход е да се реализира комбинирана схема за класификация на многоканални данни от дистанционни изследвания изградена от три обработващи блока. Изходните данни се подават на две паралелно работещи процедури за класификация едната използваща статистически метод, а другата невронна мрежа. Ако получаваните резултати за даден пиксел от двете съвпадат, то се приема че той е коректно класифициран. В случай, че има различия трета процедура използваща невронна мрежа дава крайното решение относно принадлежността на пиксела към даден клас. Изборът в качеството на арбитража процедура да се използва невронна мрежа се обуславя от факта, че тя предоставя възможността за формиране на отделни, несвързани области в пространството на признаците, отговарящи на един клас, което е особено важно при класификация на обекти от тип „смесен клас“. Като недостатък на описания подход може да се посочи усложненият процес за обучение на всяка отделна обработваща процедура. Изложената схема за използване на комбиниран подход за работа е в основата на проведени експерименти с основни типове земно покритие (Vassileva, 1999).



### 5.4.3 Класификация по МОВ с програмнен компонент ОТВ

Получаването на модел за класификация на МКСД по МОВ бе реализиран посредством наличните в програмния пакет ОТВ обработващи модули SVM и libSVM. Като критерий за качество на изградения след етап „създаване на модел“ (оценка на точността му) се използва обобщената оценка *карра* получена от матрицата на грешките получена след класификация на данните използвани на етап „валидация на модел“.

И при двете програмни реализации на процедурата, създаваща модела за класификация по МОВ в ОТВ един от входните ѝ параметри е т.нар. флаг за оптимизация, който управлява начина, по който се извършва промяната на останалите параметри на модела. Ако неговата стойност е *неистина* класификацията по МОВ върху данните за валидация ще бъде извършена само веднъж, а ако му бъде присвоена стойност *истина* итеративно се търсят оптимални параметри на модела по МОВ след 10-кратна кросвалидация. В зависимост от стойността на споменатия флаг резултатите върху едно и също множество входни данни са различни, и ако се извършва оптимизация на параметрите времето за обучение рязко нараства.

И при двете програмни реализации за създаване на модел по МОВ в ОТВ важно място заема размера на извадките използвани за обучение и валидация, тъй като от тях зависи дали полученият модел ще притежава добра възможност за обобщаване или пък ще се достигне до преобучаване на модела. Този размер се задава от потребителя, но следва да се вземе предвид, че в зависимост от избраното функционално ядро времето необходимо за обучение и създаване на модел може да бъде значително. На етап „създаване на модел“ е предоставена и възможност да се зададе съотношението между обучаващо/валидиращо множества, което по подразбиране е 0.5.

### 5.4.4 Получени резултати при прилагане на класификация по МОВ с обработващ модул SVM – ОТВ

Резултатите от етап „обучение на модел“ с различни функционални ядра, които ще се използват за последваща тематична класификация по МОВ, са показани в Таблица 9, а моделът с подчертана стойност в колоната, в която са представени стойностите на обобщената оценка *карра* е използван и за класификация на пълния набор данни. В случаите когато не се наблюдават големи промени за получаваните стойности за този параметър при различни начални стойности на параметрите  $C$  и  $\gamma$  използвани на етап „обучение на модел“ е избран този модел, който има минимални стойности за тези параметри, защото това гарантира и минимално време необходимо за създаване на модела.

вид на функционалното ядро	размер на обучаващата извадка	размер на извадката при валидация	коэффициент $C$	коэффициент $\gamma$	обобщена оценка <i>карра</i> (обуч./валид.=0.5)
1999					
<i>RBF</i>	100	1000	1	1	0.653168
	500	1000	1	1	0.715533
	500	1000	10	1	0.715533
	500	1000	10	1	0.694092 (обуч./валид.=0.7)
	500	1000	100	1	0.715533
	500	200	10	2	0.686114
	750	2000	1	1	0.717678
	750	2000	250	2	0.717678
	750	2000	250	10	0.717678
	2000	4000	1	1	0.694092
	2000	4000	10	1	0.694092
	2000	4000	10	1	<u>0.717947</u> (обуч./валид.=0.7)
	2000	4000	10	1	0.707254

вид на функционалното ядро	размер на обучаващата извадка	размер на извадката при валидация	коефициент C	коефициент $\gamma$	обобщена оценка карра (обуч./валид.=0.5)
					(обуч./валид=0.7)
	2000	4000	250	1	0.717678
<i>linear</i>	500	1000	1	1	0.579306
	500	1000	10	1	0.579306
	500	1000	250	1	0.579306
	500	1000	250	3	0.579306
	2000	2000	250	3	0.597414
	2000	4000	250	3	0.597414
	2000	4000	5	5	0.597414
	2000	4000	5	10	0.597414
	4000	4000	10	5	0.597414
<i>polynomial degree=2</i>	100	250	1	1	0.612430
	100	250	5	1	0.612430
	100	250	10	1	0.612430
	100	250	100	1	0.612430
	100	1000	100	1	0.614243
	100	4000	100	1	0.614243
	500	4000	100	1	–
	200	4000	100	1	–
	200	350	100	1	0.185810
	200	350	100	3	0.235885
	200	350	250	3	0.235885
	200	400	250	3	0.236696
	300	400	250	3	0.212170
	100	400	250	3	0.256424
2006					
<i>linear</i>	500	1000	2		0.563492
	500	1000	5		0.563489
	800	1500	5		0.650012
<i>RBF</i>	500	1000	2		0.553145
	800	1500	3		0.554129
	800	1500	5		0.545429
<i>polynomial degree=2</i>	100	250	2		0.780610
	200	500	2		0.880857

Таблица 9 Параметри на функционалните ядра и стойности на обобщената оценка карра при използване на обработващ модул SVM за реализации на модел по МОВ

От резултатите показани в горната таблица може да се направи извода, че за етап „обучение на модел“ по МОВ при прилагане на ФРБ<sup>39</sup> стойностите на карра варират в сравнително тесни граници. При този метод за създаване на модел промяната на параметрите C и  $\gamma$  не оказват съществено значение за подобряване на точността на класификация като същото може да се каже и за влиянието на размера на извадките за обучение и валидация. Използването на линейна функция за изграждане на модел по МОВ дава малко по-лоши резултати от тази при предходния модел, което се очакваше и се дължи на факта, че при нея реална трансформация на пространството на XII не се извършва<sup>40</sup>, но като негово предимство може да се посочи краткото време за обучение на модела. Следва да се отбележи, че моделът по МОВ с функция полином от втора степен даде най-добри резултати за 2006г., докато за 1999г. най-добър модел се получи при прилагане на ФРБ. Този резултат потвърждава твърдението, че с оглед постигане на оптимални резултати за класификация на конкретен

<sup>39</sup> В (Pal,2010) се подчертава, че “... ядрата, използващи функции с радиален базис губят свойството си на локални ядра при увеличаване проостранството на XII ...”.

<sup>40</sup> [http://docs.opencv.org/2.4/modules/ml/doc/support\\_vector\\_machines.html](http://docs.opencv.org/2.4/modules/ml/doc/support_vector_machines.html)

набор данни е желателно да бъдат изследвани повечето от наличните възможности, както и че няма общовалидно правило при избор на функцията реализираща функционалното ядро на етап „обучение на модел“.

От представените в същата таблица резултати е видно, че за двата набора данни има съществена разлика по отношение качеството на създавания модел на процедурата за класификация, което може да бъде обяснено с разлика в условията на средата при получаване на данните. Друга причина, на която може да бъде отдадена тази разлика е, че в единия набор МКСД спектралните класове се припокриват в по-голяма степен, отколкото в другия, което води до по-сложна форма на разделящата хиперравнина реализирана от модела и съответно по-ниска точност при прилагане на изграждания модел за класификация върху използвания набор данни за валидирането му.

#### 5.4.5 Получени резултати при прилагане на класификация по МОВ с обработващ модул *libSVM* – ОТВ

За постигане на поставените в дисертацията задачи бяха проведени и серия от експерименти за класификация на МКСД по МОВ с модели изградени от обработващ модул *libSVM*. И в този случай основен параметър, оказващ влияние върху качеството на всеки един от създаваните модели в процеса на неговото обучение, е коефициент *C* на модела, а оценка на качеството на всеки един създаден модел бе извършено посредством обобщената оценка *карра*.

вид на функционалното ядро	размер на обучаващата извадка	размер на извадката при валидация	коефициент <i>C</i>	обобщена оценка <i>карра</i>
година 1999				
<i>RBF</i>	500	1000	2	0.653952
	800	1500	2	0.654801
	800	1500	3	0.652561
	800	1500	5	<u>0.656619</u>
	500	1000	5	0.655202
<i>linear</i>	500	1000	2	0.559303
	500	1000	5	0.560038
	500	1000	10	0.560036
	800	2000	5	0.571523
	1200	2500	5	<u>0.571523</u>
<i>polynomial</i>	100	250	2	<u>0.798983</u>
година 2006				
<i>linear</i>	500	1000	2	0.546748
	500	1000	5	0.546265
	800	1500	5	<u>0.620980</u>
<i>RBF</i>	500	1000	2	0.515603
	800	1500	3	<u>0.540148</u>
	800	1500	5	0.528603
<i>polynomial</i>	100	250	2	0.724803
	200	500	2	<u>0.840863</u>

Таблица 10 Параметри на функционалните ядра и стойности на обобщената оценка *карра* при използване на обработващ модул *libSVM*

От представените в


вид на функционалното ядро	размер на обучаващата извадка	размер на извадката при валидация	коефициент <i>C</i>	обобщена оценка <i>карра</i>
година 1999				
<i>RBF</i>	500	1000	2	0.653952
	800	1500	2	0.654801
	800	1500	3	0.652561
	800	1500	5	<u>0.656619</u>
	500	1000	5	0.655202

<i>linear</i>	500	1000	2	0.559303
	500	1000	5	0.560038
	500	1000	10	0.560036
	800	2000	5	0.571523
	1200	2500	5	<u>0.571523</u>
<i>polynomial</i>	100	250	2	<u>0.798983</u>
година 2006				
<i>linear</i>	500	1000	2	0.546748
	500	1000	5	0.546265
	800	1500	5	<u>0.620980</u>
<i>RBF</i>	500	1000	2	0,515603
	800	1500	3	<u>0.540148</u>
	800	1500	5	0,528603
<i>polynomial</i>	100	250	2	0.724803
	200	500	2	<u>0.840863</u>

Таблица 10 по-горе резултати за етап „обучение на модел“ за двата набора данни (години 1999 и 2006) се вижда, че моделът с функционално ядро полином създаван от този модул дава по-добри резултати от другите два. Този модел предостави най-добри стойности за *kappa*, но трябва да се вземе пред вид и факта, че времето за обучение бе многократно по-дълго в сравнение с другите два. От същата таблица може да се направи и заключението, че увеличаването на размера на извадките за обучение и валидация не води до чувствителна промяна по отношение качеството на моделите, прилагащи функционални ядра от тип линейно и функция с радиален базис.

За разлика от разглеждания в предходния раздел програмен модул при този програмен модул е налична и още една възможност за задаване на функционално ядро – сигмоид – но проведенният експеримент за създаване на модел с него показва незадоволително качество в сравнение с останалите три (*kappa*=0,217273) и това е причината резултатите с него да не бъдат включени в сравнителната таблица.

На Фигура 29 са показани фрагменти от получените тематични изображения след класификация на пълния набор МКСД от 1999г. посредством два от изградените модели с най-добрите показатели от таблицата по-горе с насложен отгоре векторен слой с полигони от обучаващата извадка.



Линейно ядро t1200v2500c2

Ядро ФРБ t800v1500c5

Фигура 29 Резултати от класификация по МОВ реализиран от модул *libSVM* на два тестови участъка на МКСИ от 1999г.

#### 5.4.6 Получени резултати при прилагане на класификация с обработващ програмен компонент *SVM – Opticks*

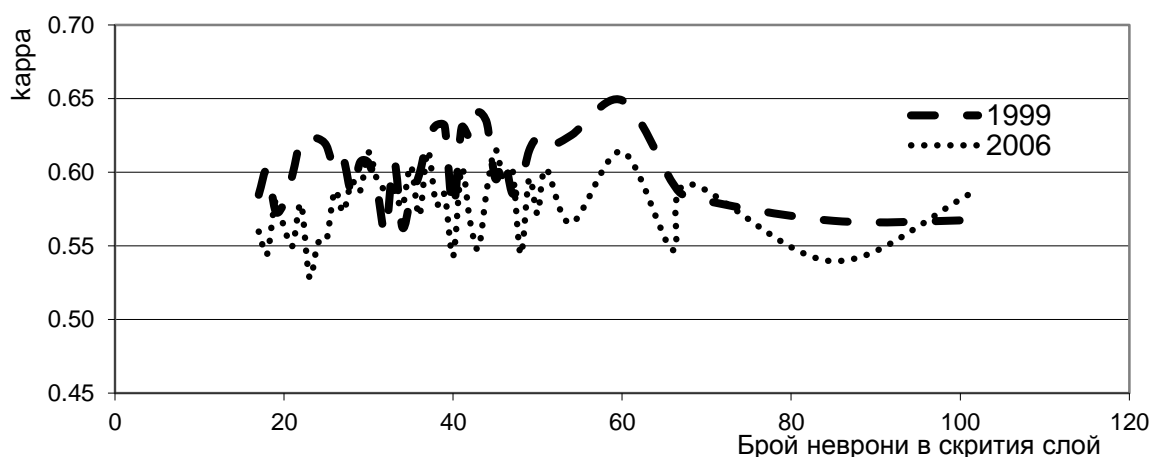
При провеждането на експерименти с този модул на етап „обучение на модел“ бе достигнато до окончателен модел само за случай на линейно функционално ядро, а при задаване на функция с радиален базис модел не се получи, тъй като модулът извеждаше

съобщение за грешка. Последното може да се дължи на различни фактора – едни от тях е ограниченият изчислителен ресурс на използваната компютърна система, а друг вероятно е големият размер на използваната обучаващата извадка. Това е причината окончателни резултати (тематични изображения, таблица на точността) да не се получат.

#### 5.4.7 Получени резултати при прилагане на класификация с обработващ модул НМ – ОТВ

На етап „обучение на модел“ с модул НМ от ОТВ при този тип модели е необходимо да се зададат следните параметри – брой на обработващите елементи в скрития слой; начални стойности на тегловните коефициенти; максимален брой итерации при обучение на модела; максимална стойност на грешката между две итерации  $\epsilon$ ; коефициент моментум.

Определящ параметър на тази тип модели е броят на обработващите елементи в скрития слой на мрежата, тъй като той определя качеството на модела т.е. точността на етап „валидация на модел“ и на етап „тематична класификация“, както и скоростта на обучението му<sup>41</sup>. Това е причината първо да се проведат експерименти насочени към установяване на техния брой с оглед получаване на максимални стойности на обобщената оценка  $kappa$ . Както се вижда от Фигура 30 стойностите на параметъра  $kappa$  за изградените модели базирани на НМ получени при неговата кросвалидация варират в интервала 0.52–0.65, не се подчиняват на функционална зависимост и имат различен характер за двата набора данни.



Фигура 30 Обобщената оценка  $kappa$  като функция на броя неврони в скрития слой

Невисоките стойности на  $kappa$  получени след етап „валидация на модел“ могат да бъдат обяснени с наличието на шум в данните, дължащ се на недобрата ПРС (30м/пиксел), която води до значителен брой пиксели съответстващи на обект от тип “смесен клас” в множествата използвани на етап „обучение на модел“, които е трудно да бъдат моделирани поради ограничения брой пиксели с напълно съвпадащи стойности в използваните спектрални интервали. Наличието на вариации в данните е предпоставка и за снижаване броя на коректно класифицираните пиксели в крайните тематични изображения, но на етап „обучение на модел“ не винаги е задължително да се търсят максимални стойности на  $kappa$ , тъй като това води до по-добра обобщаваща способност на модела (Bullinaria, 2015). От резултатите при тези експерименти броя обработващи елементи в скрития слой на НМ бяха фиксирани на следните стойности – 60 за данните от 1999г. ( $kappa=0.648766$ ) и 45 за данните от 2006г. ( $kappa=0.615275$ ).

Следващите експерименти при създаване на модел с НМ бяха насочени към достигане на оптимални стойности за останалите параметри ( $\epsilon$  и брой итерации), които следва да се зададат на етап „обучение на модел“. Получените стойности за  $kappa$  при промяна на параметър  $\epsilon$  с един порядък нагоре и надолу от стойността по подразбиране са показани в Таблица 11, а в таблица 12 е проследено влиянието на броя итерации при създаване на модела.

<sup>41</sup> Както бе споменато в предходните глави в дисертацията се разглежда структура на НМ с един скрит слой

Както се вижда от резултатите и за двата параметъра стойностите по подразбиране (изписани с курсив) се оказаха най-подходящи и в следващите експерименти не бяха променени. Необходимо е да се отбележи, че получените резултати при тяхната промяна са типичен пример за преобучаване на модел (overfitting) като при този случай моделът все повече губи способността си да обобщава, тъй като описва прекалено добре само обучаващата извадка, а при представянето на данни извън нея (в случая това е извадката за валидация на модела) не е в състояние да ги опише със задоволителна точност.

epsilon	каппа
<i>Panag-1999-TM</i>	
<i>0.01</i>	<i>0.648766</i>
0.001	0.604909
0.1	0.516694
<i>Panag-2006-TM</i>	
<i>0.01</i>	<i>0.615275</i>
0.001	0.606497
0.1	0.570998

Таблица 11 Каппа като функция на  $\epsilon$

брой итерации	каппа
<i>Panag-1999-TM</i>	
<i>1000</i>	<i>0.648766</i>
10000	0.362031
<i>Panag-2006-TM</i>	
<i>1000</i>	<i>0.615275</i>
10000	0.267366

Таблица 12 Каппа като функция на броя итерации

Друг параметър, който следва да бъде зададен на етап „обучение на модел“ с НМ, и чието влияние по отношение качеството на модела бе изследвано, е коефициента моментум (в Таблица 13 съкращението е SWGT). Този коефициент внася инерция по отношение промяната на стойностите на тегловните коефициенти и по този начин се избягва попадането в локални минимума в повърхността на грешката (вж. Фигура 17). Както се очакваше той оказва значително влияние върху крайната точност при класификация върху извадката за валидиране на модела, която варира в широки граници от 0.03 до 0.648766. Това дава основание да се направи извода, че на етап „обучение на модел“ с НМ е необходимо за него да бъде потърсена оптимална стойност с оглед повишаване на точността при тематична класификация.

SWGT	каппа
<i>Panag-1999-TM</i>	
0.5	0.066513
0.2	0.454246
<i>0.1</i>	<i>0.648766</i>
0.09	0.624354
0.06	0.629006
0.05	0.631276
0.04	0.623828
0.01	0.613259
<i>Panag-2006-TM</i>	
0.5	0.032721
0.1	0.615275
0.08	0.594168
0.06	0.600572
0.04	0.620449
0.03	0.625119
0.025	0.629251
<i>0.022</i>	<i>0.631117</i>
0.02	0.630716
0.015	0.627383
0.01	0.611396

Таблица 13 Влияние на коефициента моментум върху точността при класификация, прилагаща модел на НМ

Повтаряемост на експериментите т.е. запазване стойността на обобщената оценка  $\kappa$  до четвъртия знак се осигурява от допълнителен параметър, на който следва да се присвои целочислена стойност на етап „създаване на модел“. Ако на този параметър не му бъде присвоена конкретна стойност получаваните при всеки експеримент резултати варират в тесни граници от 1-3 процентни пункта, тъй като тя се генерира като случайно число (вж. Таблица 14).

размер на обучаващата извадка	размер на извадка за валидиране	брой обработващи елементи в скрит слой	SWGТ	моментум	$\epsilon$	$\kappa$
1000	3000	35	0.05	0.05	0.001	0.670975
1000	3000	35	0.05	0.05	0.001	0.663646
1000	3000	35	0.05	0.05	0.001	0.661780
1000	3000	35	0.05	0.05	0.001	0.671908
1000	3000	35	0.05	0.05	0.001	0.657516
1000	3000	35	0.05	0.05	0.001	0.658849
1000	3000	35	0.05	0.05	0.001	0.670975
1000	3000	35	0.05	0.05	0.001	0.647921

Таблица 14 Стойности на обобщената оценка  $\kappa$  при случайни начални стойности на тегловните коефициенти на НМ за модел на данните от година 1999.

В Таблица 15 са показани получените оптимални стойности за параметрите, при които бе извършено обучението и валидацията на модели създавани по метод с НМ. Впоследствие всеки един от двата модела беше приложен за тематична класификация на пълния набор от МКСД от съответната година.

Брой обработващи елементи в скрития слой	SWGТ	iterations	$\epsilon$	$\kappa$
<i>Panag-1999-TM</i>				
60	0.1	1000	0.01	0.648766
<i>Panag-2006-TM</i>				
45	0.022	1000	0.01	0.631117

Таблица 15 Оптимални параметри приложени на етап „създаване на модел“ с НМ използвани за класификация на пълните набор данни за години 1999 и 2006.

След създаване на двата модела по метод с НМ с тяхна помощ беше извършена класификация върху пълните набори МКСД за години 1999 и 2006 в предварително дефинираните в раздел 5.1 17 информационни класа. Получените резултати (вж. Фигура 31) под формата на растерни тематични изображения бяха оценени първо визуално, а впоследствие беше генерирана матрица на грешките<sup>42</sup> за всяко едно от тях (Story, 1986) и беше изчислена обобщената оценка  $\kappa$ . Визуалната им интерпретация бе проведена като върху полученото тематично изображение за съответната година бе наложен векторен слой от полигони от КЗП 2006, който е създаден съгласно изискванията на проекта<sup>43</sup>. Видно е, че качеството на получените резултати не е високо, тъй като в рамките на един клас дефиниран като еднороден полигон от КЗП попадат пиксели от растерния слой, които са причислени към други класове.

Тези получени резултати не следва да бъдат разглеждани като недостатък на приложената методика, тъй като при нея се реализира класификация на всеки един отделен елемент от МКСД (позната и като попикселна класификация – per pixel classification) и в този случай не

<sup>42</sup> Тази матрица е квадратна и показва броят пиксели (т.е. съответства на площ от земната повърхност) включени към конкретен клас земно покритие отнесени към реално проверени площи/пиксели (Boschetti, 2004). Матрицата на грешките се интерпретира по следния начин – сумите по редове са общият брой пиксели в изображението, което се приема за референтно, а сумите по колони са броят пиксели причислени към всеки информационен клас в класифицираното тематично изображение (Campbell, 2011).

<sup>43</sup> CORINE land cover technical guide – Addendum 2000, M. Bossard, J. Feranec and J. Otahel, May 2000, EEA

се взема под внимание класа към, който са вече са причислени съседните пиксели. Влиянието на този ефект, познат в литературата под името „сол-пипер“, е възможно да бъде намалено, ако преди класификацията се приложи обектно ориентиран анализ на изображения (ООАИ)<sup>44</sup> (Blaschke,2010), но тъй като това променя възприетата методика за постигане на целите на тази дисертация и това е причината този анализ да не бъде приложен преди създаването на модела.

От систематизираните в Таблица 16 резултати се вижда, че един от класовете (клас 243 – земеделски земи със значителни участъци естествена растителност (Корине,2016)) има най-високи стойности на неправилно класифицирани пиксели, което е резултат от наличието на спектрално разнородни пиксели в обединени в един информационен клас, докато най-коректно класифицирани са пикселите за класове 112 (населени места със свободно застрояване) и 512 (водни площи), което се дължи на тяхната спектрална еднородност.

Клас по КЗП	неправилно класифицирани обекти (commission errors)	пропуснати обекти (omission errors)
<b>1999</b>		
[243]	78.67	12.18
[313]	55.94	25.02
[242]	53.62	79.13
[324]	45.22	74.75
[131]	44.64	20.05
[231]	43.59	72.05
[132]	38.08	10.73
[333]	33.12	87.07
[121]	32.66	54.89
[321]	30.26	21.58
[222]	29.29	62.00
[312]	26.51	15.71
[322]	23.65	48.96
[211]	22.66	21.46
[311]	17.95	35.15
[112]	16.15	28.27
[512]	6.17	20.31
<b>2006</b>		
[243]	91.27	14.39
[132]	54.44	13.44
[131]	54.12	18.89
[333]	49.21	71.10
[313]	44.97	58.85
[324]	42.18	72.63
[242]	39.70	79.11
[222]	38.28	75.29
[311]	34.28	25.82
[322]	31.63	56.01
[211]	24.79	22.39
[312]	19.77	15.99
[231]	19.62	80.79


<sup>44</sup> Object based image analysis (OBIA)



Клас по КЗП	неправилно класифицирани обекти (commission errors)	пропуснати обекти (omission errors)
[121]	18.31	63.02
[321]	16.00	27.73
[112]	14.79	31.03
[512]	3.95	57.22

Таблица 16 Неправилно класифицирани обекти и пропуснати обекти по класове при класификация на пълните обеми данни за години 1999 и 2006 с модел прилагач НМ.

На Фигура 31 са показани фрагменти от тематичните изображения получени в резултат на класификацията на пълния обем данни от модели с НМ за 1999г. (а) и 2006г. (б). Както бе отбелязано и в началото на раздела в този случай се забелязва се характерното за попикселната класификация наличие на единични или малък брой пиксели включени в даден клас, но които се отличават от останалите и чието наличие води до повишаване на погрешността при валидация на тематичното изображение, използваща като референтни данни тези от векторния слой с полигони.



Фигура 31 Фрагменти от класифицираните МКСИ а) за 1999г. и б) за 2006г., включващи полигони от КЗП2006 за класове водна площ, градска част, горска и селскостопанска растителност.

Количествена оценка относно получените резултати за качеството на моделите, прилагащи НМ за двете години е представена в Таблица 17. На етап „създаване на модел“ и за двата набора данни се получиха сходни стойности за средна точност и за коефициент *kappa* при класификация извършена върху данните за валидиране на модела, но след прилагането му върху целите МКСИ се вижда, че моделът създаден на базата на МКСД за 1999г. предоставя по-добро качество.

Етап „създаване на модел“		Етап „създаване на тематично изображение“	
средна точност	<i>kappa</i>	средна точност	<i>kappa</i>
<i>Panag-1999-TM</i>			
66.94%	0.648766	61.11%	0.580763
<i>Panag-2006-TM</i>			
65.27%	0.632265	57.88%	0.549248

Таблица 17 Средна точност и оценка на параметъра *kappa* получени при класификация на данните при валидиране на моделите и при тематична класификация на пълния обем данни.

Проведена бе и още една серия експерименти насочена към получаване на подобрени модели прилагащи НМ. При нея като основна хипотеза бе поставено да се провери дали е възможно постигане на по-добра обобщаваща способност на изграждания модел, който е създаден на базата на по-малка обучаваща извадка – 200 пиксела за клас за етап „обучение на модел“ и 500 пиксела за клас при неговата валидация. Използваните на етап „създаване на модел“ с НМ МКСД бяха от година 2006, тъй като се цели повишаване на точността. Получените стойности за параметъра *kappa* при промяна на броя обработващи елементи и параметъра SWGT при създаване на модел с НМ са показани в таблица 18.

neurons in HL	SWGT	SMT	epsilon value	max num. iterations	<i>kappa</i>
15	0,1000	0,1000	0,1000	1000	0,6457730
20	0,1000	0,1000	0,1000	1000	0,6746150
25	0,1000	0,1000	0,1000	1000	0,6746150
30	0,1000	0,1000	0,1000	1000	0,6507610
35	0,1000	0,1000	0,1000	1000	0,6771290
40	0,1000	0,1000	0,1000	1000	0,6477670
45	0,1000	0,1000	0,1000	1000	0,6680000
50	0,1000	0,1000	0,1000	1000	0,6563480
55	0,1000	0,1000	0,1000	1000	0,6422740
60	0,1000	0,1000	0,1000	1000	0,6666290
65	0,1000	0,1000	0,1000	1000	0,6299370
15	0,1000	0,1000	0,1000	1000	0,6457730
15	0,0010	0,1000	0,0100	1000	0,2289460
15	0,0100	0,1000	0,0100	1000	0,6679530
15	0,0500	0,1000	0,0100	1000	0,6645730
15	0,9000	0,1000	0,0100	1000	0,2503670
15	0,0900	0,1000	0,0100	1000	0,6520090
15	0,0200	0,1000	0,0100	1000	0,6687080
15	0,0300	0,1000	0,0100	1000	0,6943340
15	0,0400	0,1000	0,0100	1000	0,6710500
15	0,0350	0,1000	0,0100	1000	0,6772720
15	0,0320	0,1000	0,0100	1000	0,6974430

neurons in HL	SWGT	SMT	epsilon value	max num. iterations	<i>kappa</i>
15	0,0330	0,1000	0,0100	1000	0,6780630
25	0,0320	0,1000	0,0100	1000	0,6819210
50	0,0320	0,1000	0,0100	1000	0,6843540
100	0,0320	0,1000	0,0100	1000	0,6625820

Таблица 18 Създаване на модел с еднослойна НМ при намален обем на извадките за обучение и валидация.

Както се вижда от получените резултати намаляването размера на извадките за обучение и валидация, както и на броя елементи в обработващия слой, не оказва съществено влияние върху достиганата от създавания модел точност на етап „валидация на модел“. Затова бе потърсено създаване на оптимален модел при минимален брой на елементите (15 неврона) в обработващия слой при промяна на другите начални параметри (резултатите са показани след празния ред в таблицата). До такъв модел бе достигнато и както се вижда от същата таблица неговата точност е по-добра от точността постигната с 35 обработващи елемента. Достигането до модел с по-малък брой неврони обаче от своя страна оказва съществено влияние върху времето за обучение на модела, което беше по-малко от една минута при всички проведени експерименти за проверка на поставената хипотеза.

В таблица 19 са показани резултатите от серия експерименти проведени с цел установяване на оптимални стойности за създаване на модел с двуслойна НМ. Както се вижда от тях наличието на два слоя не увеличава в значителна степен точността след прилагане на модела върху извадката за валидация. Това води до извода, че е по-удачно да се използват модели на НМ с един скрит слой без това да намалява значително качеството на крайния продукт и е предмет на постигане на компромис между сложност на модела и желана точност.

neurons in layer 1	neurons in layer 2	SWGT	SMT	epsilon value	max num. iterations	<i>kappa</i>
10	10	0,1000	0,1000	0,0100	1000	0,3926330
15	10	0,1000	0,1000	0,0100	1000	0,4104250
15	20	0,0100	0,1000	0,0100	1000	0,699655
15	20	0,0010	0,1000	0,0100	1000	0,205728
15	20	0,0500	0,1000	0,0100	1000	0,67584
15	20	0,0200	0,1000	0,0100	1000	0,719177
15	20	0,0250	0,1000	0,0100	1000	0,706819
15	20	0,0200	0,1000	0,0100	10000	0,281913
15	20	0,0200	0,1200	0,0100	1000	0,734792

Таблица 19 Параметри използвани при създаване на оптимален модел с двуслойна НМ

#### 5.4.8 Обобщение на получените резултати от създадените модели за тематична класификация на МКСИ с НМ и по МОВ

В таблица 20 са обобщени получените стойности за средната точност и обобщената оценка *kappa* за създадените оптимални на модели по методи МОВ и НМ при класификация върху извадката за валидация (model) и след тяхното използване за класификация на пълния набор от МКСД (classified image) за години 1999 и 2006.

SVM model			
1999		2006	
<i>Model</i>	<i>Classified image</i>	<i>Model</i>	<i>Classified image</i>
OA – 73.83%	OA – 30.91%	OA – 63.79%	OA – 32.01%
kappa – 0.7227	kappa – 0.2096	kappa – 0.6165	kappa – 0.2259
libSVM model			
1999		2006	
<i>Model</i>	<i>Classified image</i>	<i>Model</i>	<i>Classified image</i>
OA – 74.05%	OA – 31.14%	OA – 77.75%	OA – 30.14%
kappa – 0.7250	kappa – 0.2120	kappa – 0.7644	kappa – 0.2137
ANN			
1999		2006	
<i>Model</i>	<i>Classified image</i>	<i>Model</i>	<i>Classified image</i>
OA – 66.94%	OA – 61.11%	OA – 65.27%	OA – 57.88%
kappa – 0.6494	kappa – 0.5808	kappa – 0.6323	kappa – 0.5492

Таблица 20 Обобщаване на резултатите от обучение на модели по НМ и по МОВ и прилагането им върху МКСИ за изследвания район за години 1999 и 2006.

От нея е видно, че моделите създавани по МОВ имат по-добри показатели върху извадката използвана на етап „валидиране на модел“, но при класификация на пълния обем не се представят добре в сравнение с моделите прилагачи НМ. Споменатото определено подчертава предимствата на последните, в случаите когато е необходимо да се извърши обобщаване за различните обекти от цялото МКСИ изключително на базата на стойностите за спектралното им отражение. Този факт прави моделите с НМ предпочитан избор за създаване на тематични изображения на базата на МКСД в случаите, когато в пълния набор МКСД има класове спектрални данни, за които облака от стойности в пространството на ХП е доста по-голям от този използван на етап „създаване на модел“<sup>45</sup>.

Недобрите резултати от прилагане на модели с МОВ за тематичната класификация на МКСИ могат да се отдадат на факта, че разделящата хиперравнина в пространството на ХП е с доста сложна форма и за да бъде постигнато оптимално разделяне на данните се правят сериозни компромиси с нейното разположение и форма. Това показва, че при наличието на голям брой пиксели от тип „смесен клас“ в МКСД след прилагане на този тип модели за тяхната тематична класификация не може да се очакват високи стойности на средната точност.

От проведените експерименти, получените резултати и изложените в тази глава коментари може да се направят следните изводи:

1. моделите, прилагачи нелинейни методи за класификация с обучение на МКСД, предоставят достатъчно възможности за тяхното прецизиране, което да доведе до повишаване на крайната точност след тематична класификация. Това налага да бъдат търсени оптимални стойности за параметрите, които се задават на етап „създаване на модел“, но следва да се има предвид, че за всеки отделен набор МКСД те не съвпадат, от което следва, че за всеки конкретен случай се налага да бъдат намирани по емпиричен път.
2. моделите по МОВ позволяват повишаване на точността при класификация посредством трансформация в пространство на ХП с висока размерност, дори и при малък размер на обучаващата извадка, но следва да се вземе пред вид, че данните, които ще бъдат разделяни не трябва да се припокриват т.е. да се намали наличният в тях шум;

<sup>45</sup> Както бе изтъкнато в предходните раздели на тази глава полигоните използвани на етапи „създаване на модел“ и „създаване на тематично изображение“ са от КЗП, което предполага наличие на голям брой пиксели от тип „смесен клас“.

3. моделите с НМ предоставят по-добри възможности за причисляване към даден информационен клас на МКСД извън обучаващата извадка, което се базира на тяхната способност да формират отделни, несвързани подобласти в пространството на ХП, съответстващи на конкретен клас;
4. получените стойности за обобщената точност на крайните тематични изображения не са високи, но този факт може да се отдаде на основно на две причини – първо, ПРС на МКСИ използвани в процеса на изграждане на моделите не е висока, което води до наличие на повече пиксели от тип “смесен клас” в извадката използвана на етап „обучение на модел“, и второ използваните референтни полигони при създаване на матрицата на грешките бяха от проект КЗП, при които възможността за погрешност (т.е. включване на пиксели принадлежащи на друг клас) по контура им е значителна. Последното се дължи на факта, че полигоните по проект КЗП са получени от МКСД със средна ПРС, и че всеки един обект е необходимо да заема площ равна или по-голяма от минимално изискуема от проекта картируемата единица.
5. доказано бе, че усложняването на топологията на модела с НМ (т.е. използване на два обработващи слоя) не води до значително подобряване на точността на етап „валидация на модел“, докато самият модел е доста по-сложен (т.е. матрицата на тегловните коефициенти е доста по-голяма) и времетраенето на неговото създаване е по-дълго.
6. установени са значителни вариации за точността при класификация на отделните класове обекти локализиращи в изследваните набори МКСД, което се базира на получените матрици на грешките. Конкретно и за двата разглеждани набора данни най-високи стойности за неправилно класифицирани обекти има клас 243. Такъв резултат би могъл да се очаква тъй като съгласно неговата дефиниция за целите на проект КЗП той е спектрално смесен клас. Констатирани се най-малък брой погрешно разпознати обекти и за двата набора изследвани данни са при класове 112 и 512. Това би могло да се очаква тъй като и двата класа имат специфична спектрална характеристика, която позволява безпроблемното им разграничаване от останалите класове.

В заключение е необходимо да се подчертае, че изследваните в рамките на тази дисертация нелинейни модели, прилагачи МОВ и НМ, предоставят добри алтернативи в процеса на тематична класификация на МКСИ от ДИ. На базата на проведените експерименти и получени резултати бе доказано, че тяхното прилагане води до получаване на тематични изображения с параметри за точността им съпоставими, а в много случаи и по-добри, от получаваните с традиционно използвани методи при обработка на данни от ДИ.

## Приноси в дисертацията

1. Разработена е методика за извличане на единични спектри от МКСД в ГИС среда с цел формиране на извадки за обучение и валидация.
2. На основата на обобщаване на предимствата на нелинейните методи е предложен и реализиран метод за съвместно използване на статистически и нелинейни процедури за класификация на МКСД посредством използване на синтезирани и валидирани данни.
3. Проведени са серии от експерименти насочени към създаване на оптимални модели базирани на нелинейни методи (модели с НМ и по МОВ) за класификация на МКСД, при които като критерий за качество на всеки създаван модел са приложени обобщената точност при класификация и коефициент *kappa*. Реализирана е методика за намиране на оптимални стойности за  $C$  и  $\gamma$  за случай на модел по МОВ, който използва функции с радиален базис.
4. След класификация на МКСД с получените оптималните модели по методи с НМ и МОВ са създадени тематични растерни изображения на Панагюрски район.
5. Получени са оценки за точността след класификация на МКСД посредством създадените модели базирани на НМ и МОВ за всяко едно от създадените тематични изображения, на базата на които се определя тяхното качество.

### Публикации на автора по темата на дисертацията:

1. Nikolov Chr. et al., Computer generated pattern images for training object classifier for remote sensing images based on neural network, 44th Congress, International Astronautical Federation, Graz, Austria, 1993, IAF-93-B.4.94
2. Nikolov H., Nikolova-Jeliazkova N., On Application of Kernel Methods for Processing Remotely Sensed Multichannel Data, Fundamental Space Research Sunny Beach, Bulgaria, 21-28 Sep 2008.
3. Nikolov H., Improving classification of rock types in open pit mines using support vector method, 7<sup>th</sup> BgGS National Conference with International Participation "GEOPHYSICS 2015", Sofia, 2015
4. Nikolov H., Neural networks in remotely sensed data classification, XXV International Symposium on Modern Technologies, Education and Professional Practice in Geodesy and Related Fields, Sofia, Bulgaria, November 05-06, 2015, ISSN 2367 – 6051
5. Nikolov H., Support vector machines and neural networks based classifiers for multichannel data processing, XXVI International Symposium on Modern Technologies, Education and Professional Practice in Geodesy and Related Fields, Sofia, Bulgaria, November 03-04, 2016, ISSN 2367 – 6051

## Литература

- Anguita D., MBP - Matrix Back Propagation, Nov., 1993
- Ben-Hur A. and J. Weston. A User's guide to Support Vector Machines in Data mining techniques for the life sciences, Oliviero Carugo and Frank Eisenhaber (eds.), 2010.
- Blaschke, T. Object based image analysis for remote sensing. ISPRS J. Photogramm. 2010, 65, 2-16.
- Blonda P., "Support Vector Machine Classifiers and Multiple Classifier Systems for the analysis of remotely sensed data: a comparison", Joint seminar on knowledge driven Information management in Earth Observation data, held at ESRIN, Frascati, Italy, on December 5-6, 2002
- Boschetti L. , Stephane P. Flasse, Pietro A. Brivio, Analysis of the conflict between omission and commission in low spatial resolution dichotomic thematic products: The Pareto Boundary, Remote Sensing of Environment 91, 2004
- Bullinaria J., Neural Computation : Lecture 9, 2015 (<http://www.cs.bham.ac.uk/~jxb/INC/19.pdf>)
- Burges C. J.C., A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery 2, 121-167, 1998
- Campbell James B. and Randolph H. Wynne, Introduction to Remote Sensing, Fifth Edition, The Guilford Press 2011
- Cortes C. and V. Vapnik. Support vector networks. Machine Learning, 20:273–297, 1995.
- Dalponte M. et al., The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas, Remote Sensing of Environment 113, 2345–2355, 2009
- Do, C.B., Batzoglu, S., What is the expectation maximization algorithm? Nature Biotechnology, 26:897-899, 2008.
- Fauvel M. et al., Evaluation of Kernels for multiclass classification of hyperspectral remote sensing data. 2006.
- Foody G., Status of land cover classification accuracy assessment, Remote Sensing of Environment 80 (2002) pp. 185–201 (from <http://www2.geog.ucl.ac.uk/~mdisney/teaching/PPRS/papers/foody.pdf>)
- Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. IEEE Transactions on Information Theory, 14(1), 55–63.
- Jensen J., Introductory digital image processing : A Remote Sensing Perspective, 4<sup>th</sup> edition, 2015
- Kancheva R., Denitsa Borisova, Georgi Georgiev, Informational potential of vegetation spectral reflectance in anthropogenic impact studies, Annual 50 years University of mining and geology "St. Ivan Rilski", Sofia, 2003, vol.46
- Kecman V., Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models, MIT Press Cambridge, MA, USA, 2001
- Krose Ben J. A. and P. Patrik van der Smagt, An Introduction to Neural Networks, Eight edition, January 1996.
- LandsatHandBook, 2014, [http://landsathandbook.gsfc.nasa.gov/pdfs/Landsat7\\_Handbook.pdf](http://landsathandbook.gsfc.nasa.gov/pdfs/Landsat7_Handbook.pdf)
- Lee C. and D. A. Landgrebe, "Analysing high dimensional multispectral data," IEEE Trans. on Geoscience and Remote Sensing, vol. 31, pp. 792–800, July 1993.
- Li Jing, Information Visualization with Self-Organizing Maps, JASS, 2005
- Lu D. and Q. Weng, A survey of image classification methods and techniques for improving classification performance, International Journal of Remote Sensing, Vol. 28, No. 5, 2007, pp. 823–870
- Mather P., Computer Processing of Remotely-Sensed Images, Third Edition, 2004
- Melgani F., L. Bruzzone. Classification of hyperspectral remote sensing images with support vector machines IEEE Transactions on Geoscience and Remote Sensing 2004, 42(8):1778-1790
- Oommen T. et al., An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing, Mathematical Geosciences 40 (4): 409, 2008
- OSGEO4W, <http://trac.osgeo.org/osgeo4w/> , последно посетен юли 2015
- Pal, M. and Foody, G. M., Feature selection for classification of hyperspectral data by SVM, IEEE Transactions on Geoscience and Remote Sensing, 48, 2297-2307, 2010
- Plaza A. et al., Recent advances in techniques for hyperspectral image processing, Remote Sensing of Environment, Vol. 113, Suppl. 1, 2009, pp. S110–S122, Imaging Spectroscopy Special Issue
- Principles of remote sensing, Klaus Tempfli et al. (eds.), ITC, 2009. (цитирана в текста като (Tempfli, 2009))
- Remote sensing handbook, Edited by Prasad S. Thenkabail, 2016 (цитирана в текста като (Thenkabail, 2016))

Roli F., Giorgio Fumera , Support vector machines for remote sensing image classification, Proc. SPIE 4170, Image and Signal Processing for Remote Sensing VI, 160 (January 19, 2001)

Shao Y. and Lunetta R., Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points, ISPRS Journal of photogrammetry and remote sensing 70:78-87, June 2012

Soliman M., Samir A. Mohamed, A highly efficient implementation of a backpropagation learning algorithm using matrix ISA, Journal of Parallel and Distributed Computing Volume 68, Issue 7, July 2008.

Stoimenov, A., R. Vатseva, Y. Tepeliev, T. Lubenov, N. Pelova, V. Dimitrov, R. Koleva. Corine Land Cover 2006 Bulgaria Project, Proceedings of the International Symposium on “Modern Technologies, Education and Professional Practice in Geodesy and Related Fields” Sofia, 2008.

Story M., R. Congalton. Accuracy Assessment: A User's Perspective, Photogrammetric Engineering and Remote Sensing, Vol. 52 No.3, March 1986, pp. 397-399

Stoyanov V., A. Ropson, J. Eisner, Empirical Risk Minimization of Graphical Model Parameters Given Approximate Inference, Decoding, and Model Structure, Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS), 2011, Fort Lauderdale, FL, USA.

Strashimirov, S., R. Petrunov, M. Kanazirski, 2002. Porphyry-copper mineralisation in the Central Srednogorie zone, Bulgaria. Mineralium Deposita, 37, 587–598.

Vapnik V. N. and A. Y. Chervonenkis. On the uniform convergence of relative frequencies of events to their probabilities. Th. Prob. and its Applications, 17 (2):264{280, 1971.

Vapnik V., The Nature of Statistical Learning Theory. Springer-Verlag, 1995.

Vassileva I., Nikolov H, Comparative study on the results after classification of multichannel data using statistical methods and neural network approach, *Electronics and electrotechnics*, vol.3, 1999

Yaman S., Jason Pelecanos, Mohamed K. Omar, On the use of nonlinear polynomial kernel svms in language recognition, Interspeech 2012, ISCA's 13th Annual Conference, September 9-13, 2012

Yang He, Ben Ma, Qian Du Decision fusion for supervised and unsupervised hyperspectral image classification, Geoscience and Remote Sensing Symposium, IEEE International, IGARSS 2009, Vol. 4

Дистанционно зондирование. под ред. Ф. Свеина и Ш. Деивис., М., Недра, 1983. (в текста се цитира като (ДИ,1983))

Мишев Д., Дистанционни изследвания на земята от космоса., София, Изд. БАН, 1981.

Проект „Корине земно покритие 2012“, България, издание на ИАОС, 2016 (цитирана в текста като (Корине, 2016) )

Токарева, Обработка и интерпретация на данни дистанционно зондирования Земя, Томск, 2010

Уоссерман Ф., Нейрокомпютерна техника, Москва, Мир, 1992

Петков Д., Приложение на принципите на самоорганизацията в системите за дистанционни изследвания, Дисертация за получаване на научната степен „кандидат на техническите науки“, София, 1991г.

Николов Х., Д. Борисова, Д. Петков, Т. Любенов, Моделиране на обем на водно тяло в изоставени открити рудници по данни от дистанционни изследвания, XXIII Международен симпозиум СГЗБ, София, 2013

Николов Х., Д. Борисова, Д. Петков, Анализирание динамиката на малки водни тела посредством мултиспектрални серии от времеви данни, XXIV Международен симпозиум на СГЗБ, София, 2014.

Янев Т., С. Ковачев, Д. Крежова, Т. Здравев, Х. Николов, Д.Тодоров, В.Александрова, Оценка със спектрални отражателни характеристики на водния статус на селскостопанска растителност при засушаване, Втора национална конференция по слънчево-земни въздействия, 1995.

#### Използвани съкращения

ESA – European Space Agency	КЗП – проект „Корине земно покритие“
ETM+ – Enhanced thematic mapper plus	МКСА – многоканалната спектрометрична апаратура
TM – Thematic mapper	МКСД – многоканални спектрални данни
USGS – U.S. Geological Survey	МКСИ – многоканални спектрални изображения
АГК – анализ на главните компоненти	МОВ – метод на опорните вектори
БГД – гео база данни	НМ – невронна мрежа
ГИС – геоинформационна система	СКО – спектрален коефициент на отражение
ДИ – дистанционни изследвания	ФРБ – функции с радиален базис
ЕМС – електромагнитен спектър	ХП – характеризиращи признаци