

ИНСТИТУТ ПО БИОФИЗИКА И БИМЕДИЦИНСКО ИНЖЕНЕРСТВО  
БЪЛГАРСКА АКАДЕМИЯ НА НАУКИТЕ

---

**Автономни обучаващи се системи  
от потоци от данни в реално време**

## **АВТОРЕФЕРАТ**

на дисертационен труд, представен за присъждане  
на научната степен *„доктор на науките“*

Автор: проф. д-р Пламен Първанов Ангелов

---

София, 2015

Автореферат на дисертационен труд, представен за присъждане на научната степен „*доктор на науките*“ в Институт по биофизика и биомедицинско инженерство към Българската академия на науките.

Тема: **Автономни обучаващи се системи от потоци от данни в реално време**

Автор: **проф. д-р Пламен Първанов Ангелов**

2015


# СЪДЪРЖАНИЕ

|     |                                                                                                                     |    |
|-----|---------------------------------------------------------------------------------------------------------------------|----|
| 1.  | Увод .....                                                                                                          | 2  |
| 2.  | Водещи принципи на предлагания подход.....                                                                          | 6  |
| 3.  | Разделяне на пространството на данните чрез кластеринг .....                                                        | 11 |
| 4.  | Принципно нов вид размити системи, тип AnYa .....                                                                   | 13 |
| 5.  | Еволюиране на структурата на многомоделната система на основата<br>на потоци от данни.....                          | 17 |
| 6.  | Автономно обучение на параметрите на под-моделите на<br>многомоделната система на основата на потоци от данни ..... | 19 |
| 7.  | Класове задачи решавани с предлагания подход по оригинален начин.....                                               | 21 |
| 8.  | Самопострояващи се класификатори.....                                                                               | 23 |
| 9.  | Самопострояващи се регулатори .....                                                                                 | 26 |
| 10. | Сътруднически си (колабориращи) самообучаващи се системи/модели ....                                                | 28 |
| 11. | Разработени и внедрени приложения.....                                                                              | 30 |
| 12. | Теоретични обобщения, научни, научно-приложни и приложни<br>приноси .....                                           | 43 |
|     | Литература .....                                                                                                    | 45 |
|     | Списък с авторските публикации по темата .....                                                                      | 46 |

## 1. Увод

Централната тема на настоящия труд е новият подход (изложен по-подробно в авторските монографии [A1,A2], както и в статиите, описани в допълнителния списък с авторски публикации) [A3]-[A46] към проблема, който занимава учени от десетилетия насам. Той касае построяването на стройна теория за автономно (без или с минимална намеса на човека-оператор) математическо моделиране, управление/контрол, кластеринг, класификация, прогнозиране, разпознаване на откази и т. н. на динамично променящи се обекти. Неделима част представляват свързаните с тази теория и разработени на нейна основа практически (инженерни, био-, социални и т. н.) приложения, работещи в режим на *реално време* и с изчислително леки процедури, в същото време точни (не приблизителни или *ad hoc*). В изброените по-горе области съществува голямо количество изследвания и резултати, направени за режим “off-line” или за “online” режим, но за фиксирана, непроменяща се структура. В същото време потоците данни, с които сме обградени в съвременното, често имат динамично променящи се, нестационарни характеристики. Проблемът за намиране и прилагане на нови теоретични решения, методики, алгоритми и техните софтуерни реализации и практически приложения, които да имат максимална степен на автономност и да зависят само от потоците данни, взаимното разположение и плътност на данните, представлява предизвикателство с висока научна и практическа стойност.

Тази дисертация ообщава целенасочените научни изследвания на автора в продължение на последните 15-17 години и предлага една стройна теория за автономно обучаващи се и развиващи/еволюиращи системи (английското съкращение ALS е използвано във фигурите по-долу, където е предсавена връзката на предлаганата теория със съществуващите и добре развити сродни научни дисциплини). Номерацията на фигури, таблици и формули е както в книгата [A1], въз основа на която е представената докторска дисертация. На фигура 1 са използвани следните съкращения: ML – машинно обучение; SI – идентификация на системи; DM – обработка на данни (Data Mining); SA – статистически анализ; PR – разпознаване на изображения; FL – размита логика и системи и не на последно място – ALS- автономно обучаващи се системи.




Фигура 1 Научни дисциплини, тясно свързани с разглежданата тема

**Автономните системи** често са окачествявани като физически реализации на машинния интелект и на интелектуалните системи. Въпреки че самата идея за автономни системи не е нова (тук трябва да споменем работите на Я. Ципкин от 1960те [1], адаптивното управление на Астрьом и Витенмарк от 1980те [2]) един доста засилен интерес се наблюдава през последното десетилетие, свързан най-вече с големите инвестиции и интерес към безпилотни летателни апарати, автоматична и в *реално време* обработка на огромно количество данни (Big Data) от видео, социални мрежи, интернет и т. н. Тази информация се характеризира с факта, че е неструктурирана и е нужно да се изгражда автономно както самата структура на описанието (модела), така и той да се "настройва", да се оптимизират параметрите му, т. е. да се извършва идентификация. При това е нужно и важно тази идентификация да бъде както автономна от гледна точка на неучастие на човека, така и да бъде навременна, т.е. в *реално време*, online

Тръгвайки от познатата схема за автономните системи, имащи три йерархични нива (представени на фиг. 1.1 от монографията [A1]), авторът предлага една концепция за йерархична структура на системите за автономно обучение, представена на фигура 1.2. Първото, най-долно ниво на йерархията, което е аналог на прякото управление от автономните системи, по същество представлява най-често срещаната форма на параметрично обучение при зададена, непроменяща се структура. При него се цели минимизиране на грешката при обучение. На по-високото, второ ниво, се разглежда идентификация на структурата на модела/системата – проблем, който често се пропуска в изследванията. Това може да се извърши, например чрез off-line

кластеринг, както е показано на фигурата. Най-накрая, на третото, най-високо ниво на йерархията се допуска, че структурата на системата може да се развива динамично, да еволюира, например чрез еволюиращ кластеринг, както е описано в монографията по-късно, а също и в съпътстващите статии [A8], [A12], [A22], [A23], [A28], [A33], [A39], [A41], [A45], [A46].



Фигура 1.2 Графично представяне на йерархичната структура на автономно изграждащи се системи

Особено място в настоящия труд заема проблема за откриване на аномалии, новости и нетипични/отдалечени стойности (outliers detection). Този проблем има ключово място в откриване на откази (fault detection). В настоящия труд, обаче, се развива тезата, че аномалните стойности играят ключова роля също при определяне структурата на една система, съставена от под-системи, а също и в определяне на моментите, когато структурата трябва да се промени, т.е. да еволюира. От гледна точка на приложения, този проблем е важен също за редица задачи, свързани със сигурността и автономния видеоанализ.

Не на последно място в настоящия труд се подчертава разликата между добре познатите адаптивни системи [2] и предложените за първи път (в световен мащаб) от автора преди 15-17 години еволюиращи системи (подглава 1.5 от монографията [A1]).

Предложените еволюиращи системи и модели са също така сравнени с добре познатите от последните години, звучащи по подобен начин, но доста по-различни еволюционни алгоритми в под-глава 1.6 от монографията [A1]. Основната разлика между адаптивните системи [2] и еволюиращите се състои в това, че при последните структурата на системата и, съответно, моделът не са фиксирани. При тях както параметрите също така и структурата се адаптират като нараства или намалява реда на модела, броя на под-моделите, размитите правила, невроните, вероятностните разпределения и т.н.

## 2. Водещи принципи на предлагания подход

В този смисъл, разглежданите в настоящият труд автономни системи са само-организиращи се както по отношение на тяхната структура, така и по отношение на техните параметри, ред и вид. Те предполагат динамично еволюираща (dynamically evolving) структура, т. е. не фиксирана такава а допускат повишаване или намаляне на реда на системата, добавяне на локални под-модел и т.н. в *реално време*, в зависимост от разпределението на данните на базата на които те се само-построяват.

Тук трябва да се подчертае че в основата на предлаганият подход е разпределението на реалните данни. По този начин, предлаганият подход е напълно обективен.

**Двата водещи принципа са:**


### 1) "Разделяй и владей".

Тук се има предвид, че всяка една сложна (първоначално) задача би могла да се декомпозира автоматично на крайно множество прости (трактуеми) под-задачи локално в пространството на данните (наблюденията).

### 2) Адаптивност и еволюиране.

В настоящия труд се предлага един **принципно нов, нетрадиционен подход**, който **не е ограничен** от по-горните условия и в същото време е **точен** (*не приблизителен* както е традиционният), е **изчислително ефективен** и **лек** (доказано приложим за сложни задачи в реално време), **рекурсивен** и **базиран на обективни принципи** (*не субективен*, както са, например, теорията на размитите множества, логика и системи [3], теорията на вярата (belief) [4]).

В основата на новия подход е плътността на разпределение на данните, която е по-висока ако те са подобни и са близки (в пространството на данните) до повече други подобни наблюдения и, обратно, тя е по-скоро ниска ако е различно и отдалечено от други наблюдения/данни, т. е. е изолирано, виж фиг. 2.2.



Фигура 2.2 Пример за взаимно разпределение на данните/наблюденията (точка В е с висока плътност на разпределение; точка А е с ниска плътност на разпределение)

Едно много интересно и полезно свойство на въведените мерки за взаимно разпределение и подобие е че те **могат да се извеждат и обновяват рекурсивно, в реално време**, изчислително много ефективно, (2.30)-(2.32). Тези формули, които са изведени в рекурсивна форма за Евклидово разстояние, са **патентовани от автора** чрез Университета в Ланкастър, Англия [A3]. Подобни могат да се изведат също и за разстояние тип Махаланобис и косинусово разстояние [A10], [A15], [A17], [A27], [A31], [A38].

Те представляват така наречената рекурсивна оценка на плътността (на разпределение на данните), (RDE (от recursive density estimation)), представена по-подробно заедно с извеждането си в под-глава 2.5 на монографията [A1], изрази (2.33)-(2.37). В основата е израз от тип Коши (Cauchy), (2.29) от монографията [A1], който както е известно е апроксимация в първи ред на Taylor на експоненциалната функция на Gauss, изрази (2.15)-(2.19) от монографията. Този израз, за разлика от Гаусовата функция, може да се представи рекурсивно по отношение на наблюденията (отделните данни) и, по този начин, плътността на данните при произволен/неограничен брой данни може да се определи on-line и в режим на реално време.

$$p_G = \frac{1}{(2\pi\sigma^2)^{1/2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.15)$$

$$p_C = \frac{1}{\pi\gamma \left( 1 + \left( \frac{x-x_0}{\gamma} \right)^2 \right)} \quad (2.17)$$

$$e^{-\frac{\|x-\mu\|^2}{2\sigma^2}} = \frac{1}{e^{\frac{\|x-\mu\|^2}{2\sigma^2}}} \approx \frac{1}{1 + \frac{\|x-\mu\|^2}{2\sigma^2} + \dots} \quad (2.19)$$

$$d_\Lambda(x_k) = \frac{1}{1 + \frac{1}{N_\Lambda} \sum_{i=1}^{N_\Lambda} \|x_k - x_i\|^2} \quad (2.29)$$

$$D(x_k) = D^k = \frac{1}{1 + \|x_k - \mu^k\|^2 + X^k - \|\mu^k\|^2} \quad (2.30)$$

$$\mu^k = \frac{k-1}{k} \mu^{k-1} + \frac{1}{k} x_k \quad \mu^1 = x_1 \quad (2.31)$$

$$X^k = \frac{k-1}{k} X^{k-1} + \frac{1}{k} \|x_k\|^2 \quad X^1 = \|x_1\|^2 \quad (2.32)$$

където  $D$  е плътност на взаимното разпределение на данните;  
 $\mu$  е средна стойност;  
 $X$  е сумарна квадратична норма.

$$D_k = \frac{1}{1 + x_k^2 - 2x_k \frac{1}{k} \sum_{i=1}^k x_i + \frac{1}{k} \sum_{i=1}^k x_i^2} \quad (2.33)$$

$$D_k = \frac{1}{1 + x_k^2 - 2x_k \frac{1}{k} \sum_{i=1}^k x_i + \left( \frac{1}{k} \sum_{i=1}^k x_i \right)^2 - \left( \frac{1}{k} \sum_{i=1}^k x_i \right)^2 + \frac{1}{k} \sum_{i=1}^k x_i^2} \quad (2.34)$$

$$D_k = \frac{1}{1 + \left\| x_k - \frac{1}{k} \sum_{i=1}^k x_i \right\|^2 + \frac{1}{k} \sum_{i=1}^k x_i^2 - \left( \frac{1}{k} \sum_{i=1}^k x_i \right)^2} \quad (2.35)$$

Плътноста на разпределение данните оценявана за едно наблюдение (което е точка в пространството на данните) може да се дефинира *глобално* (на основата на всички наблюдения/данни/точки) или *локално* (на основата на подмножество данни).

Плътноста на данните и нейната рекурсивно оценка (RDE) са в основата на:


1. Откриване на аномалии/новости/отдалечени точки (outliers), представени в под-глава 2.6 на монографията;
2. Еволюиране на структурата на системите и моделите, описано в последните глави на монографията [A1] и съпътстващите статии [A8], [A12], [A22], [A23], [A28], [A33], [A39], [A41], [A45], [A46].

Методът за откриване на аномалии/новости/отдалечени стойности се основава на принципа на рязко и кратковременно понижаване (спад) на плътността на разпределение на данните,  $D$ , което е илюстрирано на фигури 2.5 и 2.6 за случаите на видео и потребители на телефонни услуги и описано с формулите (2.38)-(2.41).


## Обобщение на глава 2:

Въведената концепция и (патентовани) формули за RDE представляват значителна научна новост с важно практическо значение. То се основава на по-различната концепция за близостта и подобие на отделните наблюдения в пространството на данните в замяна на традиционната концепция, използвана от 2-3 столетия за честотата на наблюденията или за изкуствено предефинирани (assumed) разпределения. Предлаганият подход е точен (не приблизителен или апроксимация),

може да работи с произволно малко наблюдения и не изисква те да бъдат напълно независими (както традиционният подход прави това, но на практика пренебрегва нарушаването на това изискване). Не на последно място, изчисленията са рекурсивни и, по тази причина, изчислително много ефективни.



Фигура 2.5 Пример за откриване на интересни движещи се обекти с RDE обработка на видео в реално време, позволяваща многократно по-бърз и робастен резултат [A34].




Фигура 2.6 Пример за откриване на аномалии при ползватели на мобилни телефони в реално време - част от проект STAKE с Министерството на Отбраната на Обединеното Кралство.

### 3. Разделяне на пространството на данните чрез кластеринг

В глава 3 на представената монография [A1] са представени няколко нови метода за кластеринг, предложени от автора: eClustering, описан по-подробно в статиите [A20], [A45], [A46] и ELM съответно в [A32]. Те са представени в глава 3 като способ за автоматично, online и по еволюиращ начин разделяне на пространството на данните. Под еволюиращ способ се разбира, че броят на кластерите не е предварително зададен, нито е фиксиран по време на задачата и процеса (потока от данни), а се променя, както в посока увеличаване, така и в посока намаляване. eClustering е основан изцяло на плътността на разпределение, дискутирана в предходната глава, докато ELM е еволюиращо разширение на известния, популярен и оптимален в off-line режим т.н. “mean-shift” кластеринг алгоритъм [5] с използване на ядро (кернел) на Епанечников. В двете години, последвали публикуването на монографията [A1], авторът разработва и публикува още еволюиращи методи за кластеринг, включващи DEC, описан в статията [A7].

ELM методът е много ефективен - откривайки много точно различните модуси (modes) на функциите на разпределение (както и “mean shift” метода) той прави това значително по-ефективно изчислително, тъй като всяка точка/данна се обработва само веднъж и не се запамятава, докато mean shift методът помни всички точки и е итеративен. Двата метода дават съизмерима точност, както е демонстрирано на фигура 3.6.



Фигура 3.6 Пример за ELM; точката представлява центъра на кластерите, който действително съвпада с максимум на функцията. Забележете, че броят на функциите не е известен предварително и няма итерации за търсене.

Потенциално ограничение на метода е изискването за изпъкналост на функциите/кластерите, но това е в сила и за многократно по-бавния оригинален метод mean shift.

В заключение, научна стойност представляват, както новите методи за кластеринг (eClusteing, ELM, DEC) така и преди всичко самата концепция за еволюиращ кластеринг метод и за използването на кластеринг за определяне структурата на многомоделни задачи (авторът е сред признатите лидери в световен мащаб).

#### 4. Принципно нов вид размити системи, тип AnYa

В глава 4 на представяната дисертация [A1] авторът предлага един напълно нов, опростен вид размити системи. В теорията на размитите множества, логика и системи са широко разпространени предимно два типа модели и системи:

- 1) т. н. Мамдани (по името на Е. Мамдани, проф. в Империъл Колидж, Лондон);
- 2) т. н. Такаги-Сугено (по имената на М. Сугено и Т. Такаги, професори в Токио).

В настоящата дисертация (в монографията) [A1] както и в [A11] авторът въвежда за пръв път един нов, алтернативен и по-ефективен модел, наречен **AnYa**:

$$\begin{aligned} & Rule_i : IF(x \text{ is like } \Xi_i) \\ & THEN (y_i = X^T a_i) \end{aligned} \quad (4.16)$$


В сърцевината на този нов подход е представянето на степента на принадлежност към локалните под-модели като относителна плътност:

$$\lambda_k^i = \frac{\gamma_k^i}{\sum_{j=1}^N \gamma_k^j} \quad i = [1, N] \quad (4.14)$$


където  $\lambda^i$  е относителна плътност която задава размитото тегло на  $i$ -тия локален под-модел;  
 $\gamma^i$  е степента на принадлежност към  $i$ -тия локален под-модел задавана чрез локалната плътност;  
 $\Xi$  е облак от данни.

По този начин **не е необходимо да се дефинира функция на принадлежност за всяка променлива/вход** (традиционно, това се прави субективно или чрез апроксимация или и двете). Вместо това, авторът въвежда понятието **облак** (Cloud) от данни като алтернатива на клъстерите, който нямат определена форма, граници, параметри [A1, A11].

На фигура 4.4 са представени два облака от данни и е скициран механизмът, по който се определя относителната плътност. На фигура 5.10 е представен пример с два облака на основата на реални данни от процес на полимеризация (данни от американската корпорация The Dow Chemical). В таблица 4.1 са сравнени трите вида размити модели.



Фигура 4.4 Облаци от данни




Фигура 5.10 Облаци от данни (данни от два типа при производство на пропилен, съвместно изследване с The Dow Chemical, TX, USA) [A16].

Таблица 4.1 Сравнение на трите типа размити модели


|         | Antecedent/IF Part                   | Consequent/ THEN Part            | De-fuzzification               |
|---------|--------------------------------------|----------------------------------|--------------------------------|
| MAMDANI | Scalar, parameterized fuzzy sets     | Scalar, parameterized fuzzy sets | Centre of Gravity              |
| TS      |                                      | Functional (usually linear)      | Fuzzily weighted sum (average) |
| ANYA    | All data; non-parametric data clouds |                                  |                                |

По-нататък, в глава 4 е представена въведената от автора многомоделна само изграждаща се система тип **AnYa** и е сравнена с алтернативната известна неввро-размита система, фигура 4.7



Фигура 4.7 Многомоделна еволюираща система тип **AnYa**, която има по-малко слоя (layers), по-опростена структура от алтернативните системи. Тя саморазгражда структурата си във формата на под-моделни от невронен и/или размит характер базирани на аморфни облаци от данни. Тя може да има MIMO форма.

Тази нова система може да се интерпретира в удобен за човека-оператор вид под формата на размити правила, например, както е показано на фигура 4.8



Фигура 4.8 Система тип **AnYa** във формата на еволюиращи размити правила. Отбелязани са също нововъведените показатели за качество (възраст, ползваемост (utility), подкрепа (support)) на отделните обновяващи се автоматично online и в режим на реално време правила. Те са въведени за пръв път в редица съпътстващи статии [A40], [A45], [A46].

В заключение, в глава 4 на представената монография [A1] се въвежда един принципно нов тип размити модели (**AnYa**), който се характеризира с опростена структура, използване на облаци от данни и автоматично определяне на размитите тегла като относителна плътност на данните (един напълно обективен метод), решавайки, по

този начин, един от най-трудните проблеми на теорията на размитие множества и системи, а именно, определянето на функциите на принадлежност. Размитият характер на модела е запазен предимно и основно във формирането на сместта (blending) на отделните значително по-прости под-модели, основавайки се на известното и специфично за размитите множества свойство на дуалност и много-подчиненост. Значителна научна новост представлява също системата от типа, представен на фигура 4.7.

## 5. Еволюиране на структурата на многомоделната система на основата на потоци от данни

В глава 5 на представяната дисертация [A1] е описана подробно методиката на формиране на структурата на много моделни задачи като задача за разделяне на пространството на данните на под-пространства в рамките, на които локални под-модели със значително по-проста структура да бъдат синтезирани и обучени в режим на реално време в процеса на използване на системата (принципа „разделяй и владей“). Описани са по-подробно дефинициите и формулите за online обновяване на показателите за качество на структурата на системата/модела (възраст на облаците, подкрепа, използваемост). Показателят „възраст“, въведен за пръв път от автора през 2005 г. в доклада [A40] и използван по-късно за автоматично определяне на момента, когато е необходима промяна на структурата на системата/модела (когато втората производна на възрастта е нула и първата производна си сменя знака, което е индикация за промяна на динамиката на формиране и подкрепа за определен под-модел) [A14] е от съществен научен интерес и е новост в световен мащаб със значение за автоматично и обективно откриване на откази (faults), аномалии, новости, промяна (change detection), премествания (shift) и дрейф (дрифт) в потоци данни. Значимостта на това откритие се състои във факта, че то по обективен начин позволява изчислително много ефективна процедура да се прилага в множество инженерни и практически задачи в индустрията, сигурността (в т. ч. и кибернетичната сигурност), видеонаблюдението и т. н. Авторът използва този принцип в редица проекти, които последват тази разработка, която е също обект на (висящ) патент [A3].

Ако резюмираме, първият принцип („разделяй и владей“) ни води до декомпозиране на една първоначално сложна задача до набор от по-прости и лесно трактуеми такива. При това, в резултат на декомпозирането чрез модел от типа **AnYa** получаваме „**облаци**“ от данни (а не кластери). Разликата е че докато кластерите имат ясно очертана форма (например, при използване на Евклидово разстояние те са хипер-сфери, при използване на разстояние тип Махаланобис – те имат хипер-елипсоидна форма и т. н.), то „облаците“ нямат такава (фиг 4.4). Нещо повече, самите „облаци“, както и техният брой не е нужно да бъдат задавани предварително, с предлагания

оригинален поход те биват определяни автоматично и *online*, в *реално време* и рекурсивно.

Вторият принцип (този за адаптивност и еволюиране) засяга, както структурата на системата/модела, така и нейните/неговите параметри.


Докато на проблема за адаптивно обучение на параметрите се обръща много внимание в литературата [6], то адаптацията и еволюирането на структурата е новост като подход, особено, когато се извършва автономно, в *online* режим, рекурсивно и неитеративно. Авторът е признат пионер в това отношение с работите си от края на миналия и началото на този век [A24], [A43].

## 6. Автономно обучение на параметрите на под-моделите на многомоделната система на основата на потоци от данни

Задачата за обучението на параметрите на локалните под-модели (които са прости по структура) е добре изучена [5], но и тук има сложност, предизвикана от непостоянната, не фиксирана структура на общата система. Поради възможността за добавяне на нови под-модели или отпадане на такива динамично, за обучението на параметрите трябва да се прилага специален метод, който отчита тази *динамично еволюираща* структура на системата/модела. Този метод, въведен от автора през 2002г. [A24] се нарича размито-претеглени рекурсивни най-малки квадрати (fwRLC). Методът е описан по-подробно в глава 6 на монографията [A1].

След като един сложен проблем е декомпозиран на съвкупност от локални (в пространството на данните) опростени под-задачи, следващата логична стъпка е да се извърши идентификация на местните/локални под-модели. На локално ниво задачата за структурна идентификация (глава 6 на настоящата дисертация [A1]) може да бъде сведена до лесни за манипулиране структури (например линейни, квадратични, експоненциални/Гаусови и т. н.), т. е. нещо подобно на тухлички или на елементи на игри като Лего®, блокчета, от които може да се комбинира по-сложна структура (например, при играта от няколко типови блокчета може да се построи мост, самолет, къща и т.н.).

Този тип модели са особено привлекателни с факта, че автоматично и изцяло въз основа на разпределението на данните (**не** на субективни решения) създават и адаптивно, в *реално време* еволюират:



Фигура 4.3 Многомоделна структура еволюираща автономно

Всеки локален под-модел в този конкретен случай (без ограничаване само до такива форми) е представен с лингвистично размито правило:

$$Rule_i : IF(x_i \sim X_i) THEN ((y_{1i} LM_{1i}) AND \dots AND (y_{mi} = LM_{mi})) \quad (4.7)$$

където  $LM_{1i}$  е първият локален под-модел на  $i$ -тото правило


$X_i$  е  $i$ -тият **облак**

$n$  е броят на входовете

$m$  е броят на изходите

След като данните са групирани и, по този начин, сложната първоначално задача е декомпозирана до набор от локални под-задачи, възниква въпроса за агрегирането на локалните/частичните изходи. Тъй като разпределението на данните е по-скоро размито, без ясно очертани граници на локалните натрупвания (кластери), то една размита, претеглена сума на локалните под-модел е логична. Трябва да се подчертае, че тук говорим за много по-ограничено приложение на размитости (само на етапа на сливането на локалните под-модел, но не става дума за функции на принадлежност).

Обобщавайки, можем да представим предлагания подход по следния начин:



Фигура 15.1 Илюстрация на предлагания подход за многомоделна структура еволюираща автономно

## 7. Класове задачи решавани с предлагания подход по оригинален начин

На основата на новия подход за базирана изцяло на данните обработка авторът предлага, разработва, тества, прилага, патентова и използва редица методи за нов начин за решаване на проблемите за:

- 1) Детекция на аномалии, откази, автономна обработка на видео в реално време [A5], [A6], [A9], [A26], [A31], [A46].
- 2) Групиране и кластеринг на данни [A20], [A7], [A32].
- 3) Класификация [A18], [A19], [A25], [A35], [A37].
- 4) Управление/контрол [A21], [A29], [A30], [A42], [A44].
- 5) Прогнозиране [A2], [A7], [A8], [A12], [A13], [A22], [A23], [A28], [A33], [A39], [A41], [A45], [A46].
- 6) Само-настройващи се сензори/датчици [A16], [A36].

и т.н. които са описани по-подробно в цитираните статии.

Разгръщайки първия принцип (“разделяй и владей”) може също да отбележим че, сам по себе си, той не е нов и е успешно прилаган в математическото моделиране и теория на системите и преди. Примери за това са многомоделния подход [7], т. н. Такаги-Сугено метод [8] за размити системи, скритите Марковски модели [9] и т. н. Самото декомпозиране на една по-сложна задача на под-задачи, обаче, обикновено се извършва субективно, на основата на равномерно разпределение на данните, или чрез кластеринг [10] (но такъв, който е извършен *off-line*).

Самата идея да се строят многомоделни системи автоматично, в режим *он-лайн* е тясно свързана с т. н. концепция за еволюиращи (*evolving*) системи, въведена от автора преди около 15 години [A43], [A2], [A42], [A24]. Проблемът е, че предварително не се знае реда (броя под модели) на многомоделната система и, затова, е привлекателна възможността реда на системата, както и самите параметри на подмоделите да се определят обективно, автоматично и изцяло на основата на разпределението на данните както е в предлагания и описван подход.


По-конкретно, оригиналният метод за еволюиращ (evolving) кластеринг, eClustering [A20], [A45] както и последващите версии (еволюиращи локални средни стойности, ELM [A32]; динамично еволюиращ (evolving) кластеринг, DEC [A7], [A25]) въвеждат методи за обективно и автоматично декомпозиране на сложни задачи от тип прогнозиране, класификация, управление, филтриране, интелигентни само-настройващи се сензори/ датчици и т. н. Те се основават изцяло на *плътността* на разпределение на данните, без да се задава предварително и/или фиксира реда на модела, без да се използват параметри и прагове специфични за определен проблем или ползвател. Нещо повече, този тип методи са изчислително леки благодарение на тяхната рекурсивност, което води до много икономични изисквания към паметта и времето и са подходящи за режим на *реално време* и огромни количества данни (big data).

В основата на гореспоменатите методи, които са описани по-подробно в монографията [A1] както и в съпътстващите статии е концепцията за **плътността на данните**: логично е кластерите да се формират около данни (точки в многомерното пространство на данните) с висока плътност (като точка В от фигура 2.2) което, само по себе си, означава че тези данни/точки са наобиколени от голямо количество близки точки. Съществената разлика е, че при предлагания подход не е необходимо да се прави предположение за Гаусово или каквото и да е разпределение, не е нужно броят на данните/наблюденията да бъде голям и те да са напълно независими една от друга.

По този начин, сложни проблеми могат да бъдат анализирани и декомпозирани в пространството на данните чрез динамично еволюиращ кластеринг по обективен и автоматичен способ, в реално време, използвайки всяка данна/точка само веднъж, без да се запамятава (благодарение на обновяване на статистическите акумулирани стойности,  $\mu$  - средна стойност и  $X$  – сумарна квадратична норма).

## 8. Самопострояващи се класификатори

В представената дисертация [A1] се въвежда схема за самопострояващи и самообучаващи се класификатори, които за разлика от преди това съществуващите не са с фиксирана структура. Тези еволюиращи класификатори са **въведени за пръв път в световен мащаб** през 2006-08 от автора и не се ограничават с предопределен брой класове, правила или специфична класификационна повърхност. Те се само-образуват динамично на основата на потоците данни и на плътността на разпределение на тези данни [A18], [A19], [A25], [A35], [A37]:




Фигура 8.1 Обща схема на самопострояващите се класификатори AutoClass

За разлика от повечето съществуващи класификатори, предлаганият класификатор е основан на прототипи (виж фигура 8.2), а не на средна стойност и може да започне да се само-построява от едно наблюдение/точка без никакво предварително обучение.

Авторът въвежда за пръв път два различни по същество типа самопострояващи се класификатори, а именно:

- а) От нулев ред (това е традиционния тип класификатори, където изходът задава етикета на класа като цяло число): eClass0 и съответно AutoClass0 - новото е, че този тип класификатор е еволюиращ, т.е. броя класове може да расте (а също и да намалява), а не е пре-дефиниран;
- б) От първи ред (класификатори, при които изходът е зададен като регресионна функция на признаците, т.е като реално число): eClass1 и, съответно, AutoClass1 - този

тип класификатори е напълно нов и също е еволюиращ, т.е. броят класове може да расте (а също и да намалява), а не е пре-дефиниран.




Фигура 8.2 Илюстрация на разликата между класификатор, основан на прототипи и такъв, основан на средна стойност (каквито са болшинството съществуващи класификатори).

Крайният клас се определя чрез т.н. принцип на „победителят взема всичко“ (winner takes all) при класификатор от нулев ред или като претеглено усреднено при класификатор от първи ред.

В допълнение е въведен и принципа на многоизходен класификатор (Система тип ММО), подобна на тази, показана на фигура 4.3.

В тази глава е предложен един **нов и оригинален метод за online автоматично определяне на теглата на отделните признаци/входове**, чрез които класифицираме данните. С негова помощ, например, напълно автоматично могат да се определят малък брой признаци от значително по-голям брой първоначални такива (стотици). Това е важно за много практически задачи при които се измерват голям брой признаци, но много от тях са на практика корелирани и/или не влияят на изходите. Забележителното е, че този подбор се извършва *online*, в *реално време* и зависи единствено от взаимното разположение на данните. Методът е основан на това, че при линейни много-моделни системи (каквито са предложените класификатори) коефициентите на изходите показват важността на определен признак. Ако, например,

за един признак сумата (по брой на наблюдения/данни) на абсолютните стойности на коефициентите е близка до нула това означава, че този признак не допринася за изхода на класификатора, т.е. че неговото отстраняване няма да се отрази практически на класификационния резултат. Такива признаци могат да бъдат отстранени. Една илюстрация на акумулираните (сумирани) абсолютни стойности на теглата на признаците за една реална задача за моделиране на NOx газове от ауспусите на коли е представена на фигура 7.6. Тя показва важността на признаците/входелите на класификатора и може да се използва за редуциране на техният брой или друг вид анализ.




Фигура 7.6 Автоматичен подбор на признаци

В заключение може да се каже, че самият **принцип за самопострояване на класификатори** по отношение на **динамично еволюираща класификационна повърхнина** е нов и оригинален. Нов е и методът за *online* автоматично определяне на теглата на отделните признаци/входове, чрез които класифицираме данните.

## 9. Самопострояващи се регулатори


**Концепцията за напълно автономни регулатори** (описани в глава 9 на представяната дисертация [A1]), които сами изграждат своята структура, както и сами настройват своите параметри, е също **оригинална и предложена за пръв път в световен мащаб** през 2001 [41] и доработена по-късно [A21], [A29], [A30]. Традиционно, регулаторите имат предварително зададена структура (най-често, но не винаги, линейна). **Предлаганият подход** премахва тази необходимост и в този смисъл е **новаторски**.

**Предлаганият** eControler [A42] и AutoControl [A1, глава 9] е основаван на добре известния метод на Psaltis et al. [11] за индиректно управление (фигура 9.1), съчетани с една автономно формираща се *online* и в *реално време* структура на предлаганите регулатори тип **AnYa**.



Фигура 9.1 Схематично представяне на метода за индиректно управление по [11].

В този подход, по същество, предложените и разработени от автора в настоящата дисертация [A1] и съпътстващите статии самообучаващи се и само-построяващи се системи играят ролята на обърнат (inverse) модел на обекта на управление (plant), както е показано на фигура 9.2.




Фигура 9.2 Схематично представяне на метода AutoControl [A1]

Предлаганият само-изграждащ се регулатор е непараметричен по отношение на IF частта си (антеседентата). На изходите се разглеждат ПИД регулатори. В по-късните модификации (RECCo, [A30], [A29], [A44]) се използва също MRC (model reference control) схемата, позната от адаптивното управление. Параметрите в следствената част на регулатора се настройват в режим online и реално време с използване на тази добре позната схема за адаптивно управление [2]. Само-изграждащият се регулатор RECCo се само-обучава от действията на регулатора, наблюдавайки също реакциите на обекта на управление и средата. Той не се нуждае от каквото и да е предварително off-line обучение, нито от модел в експлицитна/явна форма. Това демонстрира, че е възможно напълно без учител (unsupervised) да се генерира, обучи и настрои нелинеен регулатор, базирано само на плътността на разпределение на данните и избиране на прототипни работни точки автономно по еволюиращ способ. Предлаганият метод е тестван на симулиран хидравличен обект, както и на лабораторен реален обект.

В заключение, концепцията за **напълно автономни регулатори** (описани в глава 9 на представяната дисертация [A1]), които сами изграждат своята структура, както и сами настройват своите параметри, е също оригинална и предложена **за пръв път в световен мащаб през 2001** [A42], [A2] и доработена по-късно [A30], [A29], [A44]. Традиционно, регулаторите имат предварително зададена структура (най-често, но не винаги, линейна). Предлаганият подход премахва тази необходимост и, в този смисъл, е **новаторски**. Интересно да се отбележи е, че предложените регулатори могат да започнат без зададена структура (или с произволна, да речем, пропорционална, ПИ или ПИД) структура), т.е. не е необходим никакъв период на предварително обучение. Това им уникално свойство ги прави много интересни, например, за роботизирани системи особено, когато се предвижда те да се използват в непознати и/или опасна среда, позволявайки на практика автономни системи да бъдат изградени не само като алгоритми, но и като физически системи, т.е. така наречените кибер-физични системи (cyber-physical systems).


## 10. Сътрудничащи си (колабориращи) самоубучаващи се системи/модели

Напълно **оригинална** (патентована в САЩ и редица Европейски страни, [A4]) е и **идеята за коопериращи автономни системи**, която беше приложена към мобилни роботи за само-локализиране и е описана по-подробно в глава 10 на монографията [A1]. Интересното в този мекод е, че се доказва, че **точно** (**не** приблизително) същия резултат би се получил ако един набор от данни се обработи съгласно предлагания подход и ако същият този набор от данни се раздели на части и всяка част се обработи също съгласно предлагания подход от различни коопериращи, работещи паралелно системи. Това е особено важно, например за роботизирани системи, при обработка на секретна информация и т. н. В тези случаи, отделните под-системи не е нужно да разполагат с всички данни и въпреки това резултата би бил абсолютно същия.



Фигури 10.1 и 10.2 (Схема на експериментите, проведени в лабораторията на автора (Intelligent Systems Research Laboratory) в Ланкастър през 2006г. с 5 мобилни робота Pioneer-3DX (обект на патент [A4])).

Те демонстрират, че абсолютно един и същи резултат може да бъде получен с използване на предложението от автора метод при положение, че всеки един от мобилните роботи (агенти) не разполага с пълната информация (данни), както ако те са разполагали с цялата информация. Този извод е много важен в контекста на т.н. “Big Data” и при паралелна обработка на информацията, както и за запазване на секретността на данни, предоставени за обработка на различни агенти/сървъри.




Фигура 10.3 Принципът на колабориращи под-системи, използващи патентованото [A4] изобретение от автора за независимо взаимно-допълващо се автономно само-обучение в реално време.

## 11. Разработени и внедрени приложения

На основата на новия и оригинален подход, описан кратко по-горе и по-детайлно в монографията [A1] и съпътстващите статии са регистрирани 5 патента и реализирани редица внедрения и приложения, включително от водещи световни фирми (като американските Ford Motor Co. и The Dow Chemical; френско-британската Thales и френската Sagem, холандската NLR, испанската CEPISA, британските BAE Systems, 4S Information Systems), а също и много-милионни научно-изследователски проекти, включително с NASA, университета Кембридж, британското Министерство на Отбраната, Европейския Съюз, GCHQ което представлява контраразузнавателната агенция на Великобритания (аналог на американските FBI и ANS).

Тези приложения са описани по-подробно в глави 11-14 на монографията [A1].


В глава 11 е описано приложението на AutoSense - самонастройващите се интелигентни сензори/датчици, които са приложени в петролната рафинерия в гр. Санта Круз, Испания. При традиционните методи, които все още се използват, са необходими ежедневни проби от около 2 литра суров петрол и часове ръчна обработка при лабораторен анализ. Това се заменя при AutoSense от автоматично и удобно измерване на температура, налягане, вискозитет и други физични величини плюс удобен **самонастройващ се и самопострояващ се** математичен алгоритъм.




Фигура 7.5 (също и фигура 11.2) Схема на AutoSense

В резултат на прилагането на AutoSense параметрите на качеството на различните продукти произвеждани от рафинерията (*керосин, нафта, газьол* и т. н.) както и на индекса на възпламеняване Abel или Pensky-Marten могат да бъдат прогнозирани с

допустимо малка грешка (около 2%, която е съпоставима с грешката при традиционните методи от около 3%) с висока честота (всеки 15 min или дори по-често докато при традиционните методи честотата е един път дневно).




Фигура 11.3 Индиректно измерване на температурата на керосин с AutoSense (реални данни от петролната рафинерия в Santa Cruz de Tenerife, Испания).



Фигура 11.4 Индиректно измерване на температурата на керосин с AutoSense (реални данни от петролната рафинерия в Santa Cruz de Tenerife, Испания) - еволюция на модела/еволюиращия интелигентен сензор.


Като входове на AutoSense за индекса на Abel, например се вземат следните физични величини, чието измерване не представлява техническа или научна сложност:

- Налягане в кулата (tower),  $p$  [kg/cm<sup>2</sup>g];
- Количество взет продукт,  $P$  [%];
- Плътност на суровия петрол(crude),  $\rho$  [g/l];
- Температурата на горната част на колоната (column overhead),  $T^{co}$  [°C];
- Пара, инжектирана в “stripper”-а на керосина (kerosene stripper), SK [kg/h];
- Температура на извлечената нафта,  $T^{ne}$  [°C].




Фигура 11.5 Еволюция на структурата на AutoSense за индиректна оценка на възпламеняване на Abel


На фигури 11.6, 11.7, 11.9 и 11.10 е илюстрирано друго приложение на AutoSense за прогнозиране на полипропилен (съвместно с The Dow Chemical, TX, USA).




Фигура 11.6 Еволюираща структура на AutoSensor, използван за прогнозиране на пропилен, съвместно изследване с The Dow Chemical, TX, USA [A16].



Фигура 11.7 Използване на AutoSense за същите данни, както и на Фигура 11.6.



Фигура 11.9 Използване на свойството на възрастта на кластерите (облаците от данни) за автоматично определяне на отместване на данните (shift), т.е. необходимостта от промяна на структурата на модела в реално време, приложено върху реални данни от процеса на производство на пропилен (същите данни както и на Фигура 11.10).




Фигура 11.10 AutoSensor: прогнозиране на пропилен, съвместно изследване с The Dow Chemical, TX, USA [A16]: сини точки съединени с линия сравнени с реалните данни измерени по-късно с газова хроматография (червени точки).

Моделът, който се получава автономно на основата на потоците реални данни може да се представи лингвистично чрез следните размити правила:


- Rule<sub>1</sub>: IF ( $x_1 \sim 24.6$ ) AND ( $x_2 \sim 26.3$ ) THEN ( $\bar{y} = -0.039 + \bar{x}_1 - 0.324\bar{x}_2$ )*
- Rule<sub>2</sub>: IF ( $x_1 \sim 39.0$ ) AND ( $x_2 \sim 43.5$ ) THEN ( $\bar{y} = -0.615 + 4.77\bar{x}_1 - 0.340\bar{x}_2$ )*
- Rule<sub>3</sub>: IF ( $x_1 \sim 46.2$ ) AND ( $x_2 \sim 49.5$ ) THEN ( $\bar{y} = -0.679 + 1.090\bar{x}_1 + 0.450\bar{x}_2$ )*
- Rule<sub>4</sub>: IF ( $x_1 \sim 45.9$ ) AND ( $x_2 \sim 49.9$ ) THEN ( $\bar{y} = -1.340 + 5.570\bar{x}_1 - 3.320\bar{x}_2$ )*
- Rule<sub>5</sub>: IF ( $x_1 \sim 36.2$ ) AND ( $x_2 \sim 43.5$ ) THEN ( $\bar{y} = -0.002 + 0.320\bar{x}_1 - 0.065\bar{x}_2$ )*
- Rule<sub>6</sub>: IF ( $x_1 \sim 31.6$ ) AND ( $x_2 \sim 38.7$ ) THEN ( $\bar{y} = -0.007 + 0.366\bar{x}_1 - 0.129\bar{x}_2$ )*

Фигура 11.8 Набор от лингвистични размити правила от тип **AnYa**, описващи реалния процес на производство на полипропилен, чрез два от най-влиятелните фактори. Моделът е получен напълно автономно и е верифициран и използван от The Dow Chemical Company, TX, USA.

Глава 12 на монографията [A1] разглежда самообучаващи се мобилни роботи. Приложението на предлагания подход към мобилни автономни роботи е много логично, тъй като те предполагат само-обучение поради своята природа. Едното от реализираните приложения касае напълно автономно изграждане на набор от визуални ориентири/забележителности (landmarks) при обиколка на мобилния робот в непозната местност/среда. Невронна мрежа която се самоизгражда (еволюира) започвайки с една празна структура (фигура 12.7).




Фигура 12.7 Самоизграждаща се (еволюираща) невронна мрежа с визуални ориентири които могат да бъдат използвани за автоматично построяване на карта на напълно непозната местност.



Фигура 12.9 Автоматично построяване на карта на напълно непозната местност.


**Глава 13** разглежда приложението на автономните самообучаващи се системи за обработка в реално време и без човешка намеса на видео информация. Това позволява автоматично засичане, разпознаване, идентифициране и следене на обекти от статични и подвижни камери, безпилотни самолети и други интересни приложения включително, но не само в отбраната и сигурността, например за смартфон.

Приципът е представен на фиг. 13.1.




Фигури 13.1 и 13.2 Блок схема на предлагания и използван метод, публикуван по-подробно в [A34].

На фигура 13.5 са показани различни методи за определяне на центъра на обекта, от който се интересуваме като предлаганият подход, базиран на максимална стойност на RDE по отношение на пространствено (в пространството на кадъра, хоризонтално-вертикално) е с червен цвят и е най-добро в сравнение с другите, използвани методи като средна стойност, например (син цвят), който силно се влияе от шума.



Фигура 13.5 Автономно идентифициране на движещи се обекти



Фигура 13.4 Механизма за автономно детектиране на пикселите от движещи се обекти чрез рязък и значим спад на плътността на разпределение.

На фигура 13.8 и формули (13.9) демонстрират автономно (и в реално време) организиращите се модели от предложения в дисертацията тип, които са представени в разбираема лингвистична форма (13.9) и визуално на фигура 13.8 със звезди - центровете на съответните 3 локални области от кадъра, за които съответните размити правила са в сила.




Фигура 13.8 Центровете на трите локални области върху кадъра.

$$\begin{aligned}
 Rule_1 : IF \left( \begin{pmatrix} h_t^* \\ v_t^* \end{pmatrix} \sim \begin{pmatrix} 283 \\ 9 \end{pmatrix} \right) THEN \begin{cases} \hat{h}_{t+1} = -4.77 + h_t + 0.068v_t \\ \hat{v}_{t+1} = 20.75 - 0.03h_t + 0.84v_t \end{cases} \\
 Rule_2 : IF \left( \begin{pmatrix} h_t^* \\ v_t^* \end{pmatrix} \sim \begin{pmatrix} 301 \\ 135 \end{pmatrix} \right) THEN \begin{cases} \hat{h}_{t+1} = 5.04 + 0.98h_t + 0.01v_t \\ \hat{v}_{t+1} = 31.48 - 0.10h_t + v_t \end{cases} \\
 Rule_3 : IF \left( \begin{pmatrix} h_t^* \\ v_t^* \end{pmatrix} \sim \begin{pmatrix} 333 \\ 354 \end{pmatrix} \right) THEN \begin{cases} \hat{h}_{t+1} = 50.37 + 0.8h_t + 0.05v_t \\ \hat{v}_{t+1} = 248.54 - 0.94h_t + 1.18v_t \end{cases}
 \end{aligned} \tag{13.9}$$

където  $h$  означава хоризонтално положение на пиксела;  
 $v$  е вертикалната координата на пиксела;  
 $*$  означава център (фокална точка) на облак (cluster), и съответно, размито правило  
 $t$  и съответно  $t+1$  са индексите на отделни кадри от видеото.


**Глава 14** разглежда приложението на автономните обучаващи се системи за разпознаване на човешка дейност, класифициране на изображения и т. н. Интересното и оригиналното е, че динамичният характер на предлагания подход обуславя възможността за динамично променящи се класове поведение на потребителите или изображенията (фиг. 14л3). При това, предварително обучение или обучение на базата на усредняване които се прилагат традиционно не е необходимо. Предлаганата система може да **започне да се самообучава започвайки на практика с нулева информация.**

Например, ако разгледаме една организация или група потребители на UNIX (по подобен начин може да се обобщи за Интернет, Tweeter и т.н.) традиционните методи предлагат да се обучи един класификатор off-line на основата на множество потребители като при това броят класове се зададе предварително, което изисква определени предварителни (и продължителни) познания за проблема. За разлика от този традиционен подход, предлаганият в настоящата дисертация [A1] и описан по-подробно в съпътстващите статии, метод може да започне да се самообучава без никаква предварителна информация и без дори да изисква броят класове да бъде зададен предварително. В допълнение, той взема под внимание индивидуалния и динамично променящ се характер на човешкото поведение (добре известно е, че човешкото поведение не е статична характеристика а се влияе от редица фактори). По този начин, авторът предлага за пръв път в света еволюиращи модели за отразяване на динамичната и индивидуална природа на човешкото поведение и демонстрира този подход например при потребители на Unix [A10], [A15], [A17]. На фигура 14.3 е представен резултат на основата на относителната честота на използване на Unix команди на базата, на които е направен профил на всеки потребител и те са автоматично групирани в “облаци” от данни и, съответно, при добавяне на етикети – в класове потребители. Този метод е напълно без учител (с изключение само на етикетите, които не са задължителни, а и не е необходимо да се поставят на всеки отделен потребител, а само на всеки клас веднъж).



Фигура 14.3 Автономно групиране на погребителите по категории (които **не са предварително зададени**).

Предлаганият подход е не само принципно различен, бидейки напълно автономен, но е и значително по-бърз при обучение и по-ефективен като краен резултат. Едно сравнение с най-добрите известни класификатори, като C5.0, SVM, NN) е показано на фиг. 14.4.



Фигура 14.4 Резултати от автономното групиране на потребителите по категории (които **не са предварително зададени**).

В заключение на част трета на дисертацията [A1], която касае приложенията на предлаганата нова методика може да подчертаем значимостта на резултатите за:

- AutoSense като уникален само-настройващ се интелигентен сензор, който, имайки лингвистично описание (виж изразите (11.8)), е способен да започне без предварителна информация и се самообучи и само-настрои, да засече промяна на тренда (shift) и да предостави по-добри прогнози/оценки от многократно по-неудобните лабораторни off-line измервания. В допълнение, той е способен също така да определи напълно автоматично набора признаци (входни физични величини), които допринасят най много за резултата. Едно сравнение с многократно по-трудоемки методи (като off-line оптимизация с генетично програмиране) демонстрира на основа реални данни от фирмата The Dow Chemical, че същите малък на брой информативни признаци/входове може да бъде открит автоматично [A15]. Интерес към тези разработки е документиран също от Honeywell (писмо за подкрепа и финансова помощ, както и покана за автора да изнесе представяне, осъществено в Аризона, САЩ през 2009);
- Напълно автономно индивидуален или група мобилни роботи са способни да се самоориентират (т. н. наречената задача SLAM - самоориентиране и картографиране) и да комуникират само едно ограничено подмножество метаданни което обаче е напълно достатъчно да се изгради точна (не приблизителна картина, каквато би се изградила с всички данни (ако бяха достъпни до всеки мобилен робот/агент). Този резултат е от съществено значение, както за роботиката, отбранителната индустрия - при т. н. автономни системи - в т. ч. и въздушни, наземни и морски - така също и за сигурността, но и за т. н. "Big Data" - при паралелезиране на обработката на потоци данни става възможно да се решават задачи, които иначе не е възможно заради хардуерни или други ограничения, преодолявайки проблем свързани с достъпа до пълната информация, прехващане на информация и т. н.
- Предлаганите нововъдения на основата на RDE и откриването на аномалии намират интересни приложения в автономната обработка на

видеоизображения с цел откриване на движещи се обекти (а също и стационарни такива, които не са били преди на определено място). Нов подход за определяне на координатите на целта е предложен и доказан да осигурява по-прецизни и по-робастни резултати. Самият RDE метод е доказан да дава на порядък по-бърз и по-робастен резултат в сравнение с аналогични съществуващи методи. Той е предоставен на OpenCV за широко потребление, но е обект на патенти [A3], [A4]. В допълнение, предлаганият подход осигурява автоматично генериране на лингвистичен и напълно разбираем модел за преместването на една цел в рамките на кадрите (виж фигура 13.8 и израз (13.9)).

- Накрая, но не на последно място, метода за динамично еволюиращи модели на потребителите е новаторски, защото не изисква никакво предварително обучение и отчита индивидуалната и потенциално динамично променяща се природа на човешкото поведение.

## 12. Теоретични обобщения, научни, научно-приложни и приложни приноси

Настоящият труд представя една нова, но вече широко използвана и утвърдена теория касаеща сложния проблем за автономно, рекурентно, неитеративно (и, по тази причина, приложимо в *реално време*) математическо моделиране, кластеринг, класификация, прогнозиране, разпознаване на откази и управление с минимална намеса на човека-оператор ограничена до задаване на входни и изходни величини, старт и аварийен стоп, задаване на ограничения свързани с безопасността.

Настоящият автореферат цели да щрихира и обобщи проблемите, новостите, приносите и резултатите от задълбочените, многогодишни и целенасочени изследвания и теоретични обобщения на автора изграждащи една цялостна теория на основата на предложените редица подходи. Подробности могат да бъдат открити в монографиите [A1], [A2] и съпътващите статии. Списък с 46 **избрани** публикации (в това число 2 изследователски монографии, 2 патента, 20 рецензирани статии във водещи научни списания, 19 доклада отпечатани в рецензирани сборници на водещи конференции и 3 глави от книги), пряко свързани с представената дисертация и предоставени в пълен текст е представен по-нататък в автореферата. Допълнително, авторът има над 80 други публикации (в т.ч. още 3 патента) отнасящи се по темата на дисертацията, които не са използвани в друга процедура и са изброени в автобиографията му (която, от своя страна, има над 200 публикации, цитирани над 3875 пъти по данни към февруари 2015г.).

На основата на предлагания подход, който е приложим *он-лайн* в реално време за всяко ново наблюдение (данна), са изградени различни решения за цели класове задачи, в това число автономно обучаващи се:

- а) класификатори;
- б) прогностични системи/модели;
- в) инферентни сензори/датчици;
- г) регулатори.

### Приложни приноси:

Направени са редица приложения и внедрявания (в това число във водещи глобални компании/фирми).

Предлаганият подход и методите са патентовани в САЩ и редица Европейски страни, [A3], [A4] и още 3 патента описани в автобиографията на автора. Те са също така лицензирани на редица американски и европейски фирми чрез Университета в Ланкастър, Англия и внедрени в множество приложения от различни области (като сигурност и отбрана, авиация, биомедицина, видеонаблюдение, химическа и петролопреработваща индустрия и т.н., включително от водещи световни фирми (като американските Ford Motor Co. и The Dow Chemical; френско-британската Thales и френската Sagem, холандската NLR, испанската CEPESA, британските BAE Systems, 4S Information Systems), а също и много-милионни научно-изследователски проекти, включително с NASA, университета Кембридж, британското Министерство на Отбраната, Европейския Съюз, GCHQ което представлява контраразузнавателната агенция на Великобритания (аналог на американските FBI и ANS). Интерес към тези разработки е документиран също от Honeywell (писмо за подкрепа и финансова помощ, както и покана за автора да изнесе представяне, осъществено в Аризона, САЩ през 2009).

Списък с 46 **избрани** публикации (в това число 2 изследователски монографии, 2 патента, 20 рецензирани статии във водещи научни списания, 19 доклада отпечатани в рецензирани сборници на водещи конференции и 3 глави от книги), пряко свързани с представената дисертация и предоставени в пълен текст е представен по-нататък в автореферата. Допълнително, авторът има над 80 други публикации (в т.ч. още 3 патента) отнасящи се по темата на дисертацията, които не са използвани в друга процедура и са изброени в автобиографията му (която, от своя страна, има над 200 публикации, цитирани над 3875 пъти по данни към февруари 2015г.).

## Литература

- [1] Y. Tsytkin, Self-learning – What is it?, *IEEE Transactions on Automatic Control*, vol. **13** (6), pp. 608-612, Dec. 1968.
- [2] K. Astroem, B. Wittenmark, *Adaptive Control*, Addison Wesley, Massachusetts, USA, 1989.
- [3] L. A. Zadeh, Fuzzy sets, *Information and Control*, vol. 8 (3), pp. 338-353, 1965.
- [4] A. P. Demspster, A Generalization of Bayesian Inference, *Journal of Royal Statistics Society*, vol. **30**: pp. 205-247, 1968.
- [5] D. Comaniciu, Mean shift: a Robust Approach Toward Feature Space Analysis, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. **24** (5), pp. 603-619, May 2002.
- [6] L. Ljung, *System Identification: Theory for the User*, Prentice-Hall: New Jersey, USA, 1987.
- [7] V. Petridis, A. Kehagias, A Multi-model Algorithm for Parameter Estimation of Time-varying Nonlinear Systems, *Automatica*, vol. **34** (4), pp. 469-475, April 1998.
- [8] T. Takagi, M. Sugeno, Fuzzy Identification of Systems and Its Application to Modeling and Control, *IEEE Trans. on Systems, Man and Cybernetics*, vol. **15** (1): pp. 116-132, 1985.
- [9] R. Rabiner, A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, *Proceedings of the IEEE*, vol. **77** (2): pp. 257-286, Feb. 1989.
- [10] R. Babuška, H. B. Verbruggen, Constructing Fuzzy Models by Product Space Clustering, In: *Fuzzy Model Identification* (H. Hellendoorn, D. Driankov Eds.), pp. 53-90, Springer Verlag, 1997.
- [11] D. Psaltis, A. Sideris, A. Yamamura, A Multilayered Neural Network Controller, *IEEE Control Systems Magazine*, vol. **8** (2), pp.17-21, 1988.

## Списък с авторските публикации по темата

Списъкът съдържа 46 подбрани публикации, пряко свързани с темата на докторската дисертация, неизползвани преди това в друга процедура и предоставени в пълен текст, в това число: 2 изследователски монографии, 20 рецензирани статии във водещи научни списания, 19 доклада отпечатани в рецензирани сборници на водещи конференции, 2 патента и 3 глави от книги.

Допълнително, авторът има над 80 други публикации (в т.ч. още 3 патента) отнасящи се по темата на дисертацията, които не са използвани в друга процедура и са изброени в автобиографията му (която, от своя страна, има над 200 публикации, **цитирани над 3900 пъти** по данни на Google Scholar към февруари 2015г.). Най-цитираната статия [A22] е цитирана **над 614 пъти**.

Използвани означения:

\* наградена (**best paper award**) публикация

\*\* номинирана за награждаване (**outstanding publication, IEEE Transactions on Fuzzy Systems, импакт фактор (иф) = 6.306**) публикация

### Изследователски монографии (2):

A1. P. Angelov, *Autonomous Learning Systems: From Data Streams to Knowledge in Real time*, John Wiley and Sons, Dec.2012, ISBN: 978-1-1199-5152-0.; **25** цитирания.

A2. P. P. Angelov, *Evolving Rule-based Models: A Tool for Design of Flexible Adaptive Systems*, Springer-Verlag, Heidelberg, New York, 2002, 215 pp., ISBN 3-7908-1457-1; **211** цитирания.

### Патенти (2)

A3. P. Angelov, *Anomalous System State Identification*, **GB1208542.9**, priority date **15 May 2012**.

A4. P. Angelov, *Machine Learning (Collaborative Systems)*, USA **patent 8250004**, granted 21 August 2012; priority date: 1 Nov. 2006; international filing date 23 Oct. 2007.

### Рецензирани статии във водещи научни списания (20):

A5. B. S. J. Costa, P. P. Angelov, L. A. Guedes, Fully unsupervised fault detection and identification based on recursive density estimation and self-evolving cloud-based classifier, *Neurocomputing*, ISSN: 0925-2312, Feb. 2015, vol. **150**, part A: pp. 289-303; **иф = 2.102**.

A6. B. S. J. Costa, P. P. Angelov, L. A. Guedes, Real-Time Fault Detection using Recursive Density Estimation, *Journal of Control, Automation and Electrical Systems*, ISSN: 2195-3880, Aug. 2014, vol. **25** (4): 428-437, **1 цитиране**; **импакт фактор иф = 1.06**.

A7. R. D. Baruah, P. Angelov, DEC: Dynamically Evolving Clustering and its Application to Structure Identification of Evolving Fuzzy Models, *IEEE Trans. on Cybernetics*, Dec. 2013, vol. **44** (9), pp.1619-1631, **1 цитиране**; **иф = 3.236**.

A8. M. Pratama, S. Anavatti, P. Angelov, E. Lughofer, PANFIS: A Novel Incremental Learning Machine, *IEEE Transactions on Neural Networks and Learning Systems*, 2014, *IEEE Transactions on Neural Networks and Learning Systems*, vol. **25** (1): 55-68, Jan. 2014, **33 цитирания**; **иф = 2.633**.

A9. P. Angelov, R. Yager, Density-based Averaging - a new Operator for Data Fusion, *Information Systems*, vol. **222**, pp.163-174, 2013, **17 цитирания**; **иф = 3.969**.

- A10. J. Iglesias, **P. Angelov**, A. Ledezma, A. Sanchis, Creating Evolving user Behavior Profiles Automatically, *IEEE Transactions on Knowledge Data Engineering*, vol. **24** (5), pp.854-867, May 2012, **46** цитирания; иф = **1.815**.
- A11. **P. Angelov**, R. Yager, A New Type of Simplified Fuzzy Rule-based Systems, *International Journal of General Systems*, vol. **41** (2), 163-185, Jan. 2012, **30** цитирания; иф = **0.786**.
- A12. **P. Angelov**, Fuzzily Connected Multi-Model Systems Evolving Autonomously from Data Streams, *IEEE Transaction on Systems, Man, and Cybernetics- part B, Cybernetics*, vol. **41**, (4), pp. 898-910, Aug. 2011, **35** цитирания; иф = **3.236**.
- A13. J. de Jesús Rubio, **P. Angelov**, E. García, An uniformly stable backpropagation algorithm to train a feedforward neural network , *IEEE Transaction on Neural Networks*, vol.**22** (3) pp. 356-366, March 2011, **41** цитирания; иф = **2.633**.
- A14. E. Lughofer, **P. Angelov**, Handling Drifts and Shifts in On-line Data Streams with Evolving Fuzzy Systems, *Applied Soft Computing* (Elsevier), vol. **11** (2), pp. 2057-2068, March 2011, **69** цитирания; иф = **2.970**.
- A15. J. A. Iglesias, **P. Angelov**, A. Ledezma, A. Sanchis, Human Activity Recognition based on Evolving Fuzzy Systems, *International Journal of Neural Systems*, vol. **20** (5), 2010, pp.355-364, **25** цитирания; иф = **2.516**.
- A16. **P. Angelov**, A. Kordon, Adaptive Inferential Sensors based on Evolving Fuzzy Models: An Industrial Case Study, *IEEE Transaction on Systems, Man & Cybernetics-B*, vol. **40** (2), pp.529-539, April 2010, **35** цитирания; иф = **3.236**.
- A17. J. A. Iglesias, **P. Angelov**, A. Ledezma, A. Sanchis, Evolving Classification of Agents' Behaviours: A General Approach, *Evolving Systems*, ISSN 1868-6478, vol.1 (3), Oct. 2010, pp.161-171, **39** цитирания.
- A18. \*\* **P. Angelov**, X. Zhou, Evolving Fuzzy-Rule-based Classifiers from Data Streams, *IEEE Trans. on Fuzzy Systems*, ISSN 1063-6706, vol. **16** (6) 1462-1475, Dec. 2008, **172** цитирания; иф = **6.306**.
- A19. **P. Angelov**, E. Lughofer and X. Zhou, Evolving Fuzzy Classifiers with Different Architectures, *Fuzzy Sets and Systems*, **159**, 3160-3182, 2008, **106** цитирания; иф = **2.263**.
- A20. **P. Angelov**, An Approach for Fuzzy Rule-base Adaptation using On-line Clustering, *International Journal of Approximate Reasoning*, vol. 35 , No 3, pp. 275-289, March 2004, **122** цитирания; иф = **2.072**.
- A21. **P. P. Angelov**, A Fuzzy Controller with Evolving Structure, *Information Sciences*, vol. **161**, 21-35, 2004, **61** цитирания; иф = **3.969**.
- A22. **P. Angelov**, D. Filev, An Approach to On-line Identification of Takagi-Sugeno Fuzzy Models, *IEEE Trans. on System, Man, and Cybernetics, part B - Cybernetics*, vol. **34** (1) 484-498, 2004, **608** цитирания, иф = **3.236**.
- A23. **P. Angelov**, D. Filev, Flexible Models with Evolving Structure, *International Journal of Intelligent Systems*, vol. **19** (4) 327-340, April 2004, **45** цитирания; иф = **1.41**.
- A24. **P. Angelov**, R. Buswell, Identification of Evolving Rule-based Models, *IEEE Trans. on Fuzzy Systems*, vol. **10** (5) 667-677, 2002, **102** цитирания; иф = **6.306**.

### Рецензирани доклади в сборници на водещи конференции (19):

- A25. R. D. Baruah, **P. Angelov**, D. Baruah, Dynamically Evolving Fuzzy Classifier for Real-time Classification of Data Streams, *2014 World Congress on Computational Intelligence, WCCI-2014*, 6-11 July 2014, Beijing, China, pp.383-389.
- A26. B. S. J. Costa, **P. Angelov**, L. A. Guedes, A new Unsupervised Approach to Fault Detection and Identification, *2014 World Congress on Computational Intelligence, WCCI-2014*, 6-11 July 2014, Beijing, China, pp.1557-1564.
- A27. **P. Angelov**, D. Kangin, X. Zhou, D. Kolev, Symbol Recognition with a new Autonomously Evolving Classifier AutoClass, *In Proc. 2014 IEEE Conference on Evolving and Adaptive Intelligent Systems, EAIS-2014*, 2-4 June, 2014, Linz, Austria, pp.1-7, DOI 10.1109/EAIS.2014.6867482.
- A28. R. D. Baruah, **P. Angelov**, Online Learning and Prediction of Data streams using Dynamically Evolving Fuzzy Approach, *In Proc., 2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2013)*, IEEE Press, pp.1-8, ISBN 978-1-4799-0020-6, DOI: 10.1109/FUZZ-IEEE.2013.6622517, **5** цитирания.
- A29. \*B. Costa, I. Skrjanc, S. Blazic, **P. Angelov**, A practical implementation of self-evolving cloud-based control of a pilot plant, *2013 IEEE International Conference on Cybernetics, CYBCONF-2013*, Lausanne, Switzerland, pp.7-12, IEEE Press, 13-15 June, 2013, ISBN: 978-1-4673-6469-0/13, **6** цитирания.
- A30. **P. Angelov**, I. Skrjanc and S. Blazic, Robust Evolving Cloud-based Controller for a Hydraulic Plant, *Proc. IEEE Symposium Series on Computational Intelligence SSCI-2013*, 16-19 April 2013, Singapore, IEEE Press, ISBN 978-1-4673-5855-2/13, pp.1-8, **3** цитирания.

- A31. D. Kolev, **P. Angelov**, G. Markarian, M. Suvorov and S. Lysanov, ARFA: Automated Real-time Flight Data Analysis using Evolving Clustering, Classifiers and Recursive Density Estimation, *Proc. IEEE Symposium Series on Computational Intelligence SSCI-2013*, 16-19 April 2013, Singapore, ISBN 978-1-4673-5855-2/13, pp. 91-97, **6** цитирования.
- A32. R. D. Baruah, **P. Angelov**, Evolving Local Means Method for Clustering of Streaming Data, In *Proc. 2012 World Congress on Computational Intelligence, WCCI-2012*, 10-15 June 2012, Brisbane, Australia, pp.2161-2168 (IEEE Press ISBN 978-1-4673-1489-3), **12** цитирования.
- A33. **P. Angelov**, X. Zhou, On Line Learning Fuzzy Rule-based System Structure from Data Streams, *2008 IEEE World Congress on Comp. Intel.*, WCCI-2008, Hong Kong, June 1-6, 2008, ISBN 978-1-4244-1821-3/08, pp.915-922, **35** цитирования.
- A34. **P. Angelov**, R. Ramezani, X. Zhou, Autonomous Novelty Detection and Object Tracking in Video Streams using Evolving Clustering and Takagi-Sugeno type Neuro-Fuzzy System, *2008 IEEE World Congress on Computational Intelligence*, Hong Kong, June 1-6, 2008, ISBN 978-1-4244-1821-3/08, pp.1457-1464, **25** цитирования.
- A35. **P. Angelov**, X. Zhou, E. Lughofer, D. Filev, Architectures of Evolving Fuzzy Rule-based Classifiers, *2007 IEEE Intern. Conf. on Systems, Man and Cybernetics*, Montreal, Canada, ISBN 1-4244-0991-8/07, pp.2050-2055, **19** цитирования.
- A36. J. J. Macias-Hernandez, **P. Angelov**, X. Zhou, Soft Sensor for Predicting Crude Oil Distillation Side Streams using Takagi Sugeno Evolving Fuzzy Models, *2007 IEEE International Conference on Systems, Man, and Cybernetics*, Montreal, Canada, ISBN 1-4244-0991-8/07, pp.3305-3310, **20** цитирования.
- A37. **P. Angelov**, X. Zhou, F. Klawonn, Evolving Fuzzy Rule-based Classifiers, *2007 IEEE Intern. Conf. on Comp. Intel. Applications for Signal and Image Processing*, April 1-5, 2007, Hawaii, USA, pp.220-225, **43** цитирования.
- A38. X. Zhou, **P. Angelov**, An Approach to Autonomous Self-localization of a Mobile Robot in Completely Unknown Environment using Evolving Fuzzy Rule-based Classifier, *2007 IEEE Intern. Conf. on Comp. Intel. Applications for Defense and Security*, April 1-5, 2007, Honolulu, Hawaii, USA, pp.131-138, **7** цитирования.
- A39. **P. Angelov**, X. Zhou, Evolving Fuzzy Systems from Data Streams in Real-Time, *2006 Intern. Symposium on Evolving Fuzzy Syst.*, 7-9 Sept.2006, Ambleside, UK, IEEE Press, ISBN 0-7803-9719-3, pp. 29-35.
- A40. **P. Angelov**, D. Filev, Simpl\_eTS: A Simplified Method for Learning Evolving Takagi-Sugeno Fuzzy Models, *The 2005 IEEE International Conference on Fuzzy Systems FUZZ-IEEE*, Reno, Las Vegas, USA, 22-25 May 2005, ISSN 0-7803-9158-6/05, pp.1068-1073, **142** цитирования.
- A41. **P. Angelov**, C. Xydeas, D. Filev, On-line Identification of MIMO Evolving Takagi-Sugeno Fuzzy Models, *Intern. Joint Conf. on Neural Networks and Intern. Conf. on Fuzzy Syst., IJCNN-FUZZ-IEEE*, Budapest, Hungary, 25-29 July, 2004, ISBN 0-7803-8354-0, pp. 55-60, **35** цитирования.
- A42. **P. Angelov**, R. Buswell, J. Wright, D. Loveday, Evolving Rule-based Control, *EUNITE Symposium*, 13-15 December 2001, Tenerife, Spain, pp.36-41, **8** цитирования.
- A43. **P. Angelov**, R. Buswell, Evolving Rule-based Models: A Tool for Intelligent Adaptation, *9<sup>th</sup> IFSA World Congress*, Vancouver, BC, Canada, 25-28 July 2001, pp.1062-1067, **45** цитирования.

### Глави от книги (3)

- A44. **P. Angelov**, I Skrljanc, S. Blazic, Self-learning Controllers, In *Springer Handbook on Computational Intelligence*, (O. Castillo and P. Melin Ed.), part G, chapter 75, pp. 1433-1447, January 2015.
- A45. **P. Angelov**, Evolving Takagi-Sugeno Fuzzy Systems from Data Streams (eTS+), In ***Evolving Intelligent Systems: Methodology and Applications*** (Angelov P., D. Filev, N. Kasabov Eds.), John Willey and Sons, pp. 21-50, ISBN: 978-0-470-28719-4, Feb. 2010, **57** цитирования.
- A46. **P. Angelov**, Evolving Fuzzy Systems, In *Encyclopaedia on Complexity and System Science* (Bob Meyers Editor-in-Chief), ISBN: 978-0-387-75888-6, Springer, June 2009, pp.3242-3255, **174** цитирования.

За оригиналните си разработки в областта на автономните системи авторът е награден с наградата *За заслуги* на Обществото за Изчислителен Интелект към IEEE и от INNS през 2013 в Далас, Тексас, САЩ (първата снимка по-долу) както и с наградата *Инженер 2008* в Кралското Общество (втората снимка по-долу).



Фото от награждаването с наградата *За заслуги* на Обществото за Изчислителен Интелект към IEEE и от INNS през 2013 в Далас, Тексас, САЩ (авторът е в центъра).



Фото от награждаването с наградата *Инженер 2008* в Кралското Общество (авторът е последния вдясно до водещия технологични програми в BBC Rory Cellan Jones).