

O NOUĂ ȘI ROBUSTĂ TEHNICĂ DE CLUSTERING DESTINATĂ PROGRAMELOR DE PROIECTARE OPTIMALĂ

Daniela JUCAN, Lucian TUDOSE
Universitatea Tehnică Cluj-Napoca

In this paper, a new simple and robust clustering technique addressed to optimal design is presented. This technique is based on the assumption that any couple formed by a set of points and its envelope, in the n -dimensional space, is characterized by a unique real number, named t_{Ω_m} -threshold that is able to describe the state of uniform cover. The algorithm was implemented in our new software (*GetCluster v. 1.0*).

1. NECESITATEA TEHNICILOR DE CLUSTERING IN PROIECTAREA OPTIMALĂ

În proiectarea optimală, Algoritmii Genetici reprezintă, poate, cele mai utilizate metode de optimizare. O problemă importantă este aceea a gestionării funcțiilor obiectiv multimodale. Autorii lucrării consideră că se poate dezvolta o nouă categorie de algoritmi de optimizare care să includă module de clustering. Aceste module vor fi necesare în următoarea modificare a Algoritmului Genetic:

La un moment dat evoluția populației se oprește și se identifică aglomerările, grupurile (clusterelor) din spațiul variabilelor (genelor) cu speranța ca aceste cluster, lăsate ulterior să evolueze ca populații independente, să conducă, fiecare, la identificarea unui alt punct de extrem local al funcției obiectiv (multimodală).

Este evident că un astfel de algoritm de clustering nu va fi necesar să fie extrem de precis, ci va trebui să aibă alte calități, și anume:

- să identifice rapid numărul de cluster existente în populație;
- să fie cât mai simplu;
- să fie foarte rapid;
- să fie robust.

Autorii lucrării propun aici o nouă tehnică de clustering, ce a dat rezultate foarte bune în implementările ei în programele proprii de optimizare cu Algoritmi Genetici.

De remarcat că această tehnică a fost implementată cu succes și într-un modul de *pattern recognition* necesar funcționării unui robot industrial.

2. NOUA TEHNICĂ DE CLUSTERING

2.1 Axiome și definiții

Se consideră o mulțime $\Omega_m \subset \mathbb{R}^n$, adică o listă neordonată ce cuprinde coordonatele, în spațiul cu n dimensiuni, a celor m puncte ce urmează a fi supuse clustering-ului.

$$\Omega_m = \left\{ M_1(x_1^1, x_2^1, \dots, x_n^1), M_2(x_1^2, x_2^2, \dots, x_n^2), \dots, M_m(x_1^m, x_2^m, \dots, x_n^m) \right\} \quad (1)$$

Reamintim că nu se cunoaște *a priori* numărul de cluster existente în mulțime și că această sarcină revine algoritmului propus. Pentru înțelegerea tehnicilor noi de *clustering* propuse, se propun aici câteva axiome și definiții ale noțiunilor importante:

Definiția 1. Pentru fiecare mulțime Ω_m se definește n -paralelipipedul cuprinzător ca fiind mulțimea:

$$S_{\Omega_m} = \left\{ (x_1, x_2, \dots, x_n) \mid x_1^{\min} \leq x_1 \leq x_1^{\max}, x_2^{\min} \leq x_2 \leq x_2^{\max}, \dots, x_n^{\min} \leq x_n \leq x_n^{\max} \right\} \quad (2)$$

unde

$$x_i^{\min} = \min \{x_i^1, x_i^2, \dots, x_i^m\}, \quad (\forall) i \in \{1, 2, \dots, n\}$$

$$x_i^{\max} = \max \{x_i^1, x_i^2, \dots, x_i^m\}, \quad (\forall) i \in \{1, 2, \dots, n\}$$

Axioma 1. Pentru fiecare cuplu (Ω_m, S_{Ω_m}) există o unică valoare prag (threshold) $t_{\Omega_m} > 0$ ce descrie situația în care mulțimea Ω_m acoperă „uniform” n -paralelipipedul S_{Ω_m} .

Axioma 2. Mulțimea Ω_m acoperă „uniform” n -paralelipipedul S_{Ω_m} dacă și numai dacă distanța euclidiană dintre oricare două puncte ale mulțimii Ω_m este egală cu pragul t_{Ω_m} :

$$d(M_i, M_j) = \sqrt{(x_1^i - x_1^j)^2 + (x_2^i - x_2^j)^2 + \dots + (x_n^i - x_n^j)^2} = t_{\Omega_m}, \quad (\forall) i, j \in \{1, 2, \dots, m\}, i \neq j \quad (3)$$

Definiția 2. Fie $M_i \in \Omega_m$ un punct oarecare. Punctul $M_j \in \Omega, j \neq i$ se numește t_{Ω_m} -vecin (neighbour) punctului M_i dacă:

$$d(M_i, M_j) = \sqrt{(x_1^i - x_1^j)^2 + (x_2^i - x_2^j)^2 + \dots + (x_n^i - x_n^j)^2} \leq t_{\Omega_m}, \quad i \neq j \quad (4)$$

Definiția 3. O submulțime $C_{\Omega_m} \in \Omega_m$ este un t_{Ω_m} -grup (cluster) dacă oricare două puncte $M_{i,j} \in C_{\Omega_m}, j \neq i$ sunt t_{Ω_m} -vecine (neighbours):

$$d(M_i, M_j) = \sqrt{(x_1^i - x_1^j)^2 + (x_2^i - x_2^j)^2 + \dots + (x_n^i - x_n^j)^2} \leq t_{\Omega_m}, \quad (\forall) M_{i,j} \in C_{\Omega_m}, j \neq i \quad (5)$$

Definiția 4. Numărul de clustere al mulțimii Ω_m este numărul de t_{Ω_m} -grupuri (clusters) în care se grupa mulțimea respectivă.

2.2 Calculul valorii de prag t_{Ω_m}

Este evident că identificarea corectă a valorii de prag t_{Ω_m} este esențială pentru construirea unui algoritm eficient pentru clustering-ul unei mulțimi. Autorii articolului propun următoarea definiție pentru t_{Ω_m} :

Definiția 5. Valoarea de prag t_{Ω_m} atașată cuplului (Ω_m, S_{Ω_m}) se definește ca fiind lungimea laturii simplexului S_{x_n} care are volumul de m ori mai mic decât volumul n -paralelipipedului S_{Ω_m} :

$$t_{\Omega_m} = l(V(S_{x_n})) = l\left(\frac{V(S_{\Omega_m})}{m}\right) \quad (6)$$

Pentru exemplificare, se vor trata aici numai cazurile 2D și 3D.

2.2.1. Valoarea de prag t_{Ω_m} în cazul 2D

Se consideră o mulțime $\Omega_m \subset \mathbb{R}^2$ ce cuprinde m puncte din plan ce urmează a fi supuse clustering-ului.

$$\Omega_m = \left\{ M_1(x_1^1, x_2^1), M_2(x_1^2, x_2^2), \dots, M_m(x_1^m, x_2^m) \right\} \quad (7)$$

Dreptunghiul cuprinzător (fig.1) va fi definit ca mulțimea:

$$S_{\Omega_m} = \left\{ (x_1, x_2) \mid x_1^{\min} \leq x_1 \leq x_1^{\max}, x_2^{\min} \leq x_2 \leq x_2^{\max} \right\} \quad (8)$$

