Tehnici înrudite cu calculul evolutiv

- Modelul sistemului imunitar (AIS – Artificial Immune systems)
- Modelul bacterial (BFO – Bacterial Foraging Optimization)
- Algoritmi evolutivi bazati pe diferențe (DE – Differential Evolution)
- Algoritmi bazați pe estimarea unei distribuții de probabilitate (PMB - Probabilistic Model Building Algorithms)
- Algoritmi de căutare bazați pe liste tabu (TS – Tabu Search)
- Algoritmi memetici (MA – Memetic Algorithms)

Sisteme imunitare naturale/artificiale

Sistem imunitar natural: un sistem complex de componente celulare și moleculare având rolul de a identifica ceea ce este propriu organismului și de a-l apăra impotriva organismelor și substanțelor străine (agenții patogeni de tipul microbilor și virușilor).

Sistem imunitar artificial (AIS – Artificial Immune Systems): sistem adaptiv inspirat de imunologie si aplicat in rezolvarea unor probleme complexe [De Castro and Timmis,2002]

http://www-users.cs.york.ac.uk/jtimmis/utm/ais-course.html

Sisteme imunitare artificiale

Scurt istoric: domeniu inițiat la mijlocul anilor 1980

- 1990 – Ishida prima utilizare a algoritmilor inspirați de imunologie în rezolvarea problemelor

- Mijlocul anilor 1990:
  - Forrest et al: aplicații în securitatea calculatoarelor
  - Hunt et al: aplicații în analiza datelor
- Inceputul anilor 2000
  - deCastro, Timmis: optimizare multimodală

- Tendința actuală: modelarea caracteristicilor sistemului biologic

[http://www-users.cs.york.ac.uk/jtimmis/utm/ais-course.html]

Caracteristici

Sistem imunitar natural

- Specific fiecărui individ
- Distribuit
- Detecție a anomaliilor
- Invățare/adaptare
- Memorie
- Extragere caracteristici

Sistem imunitar artificial

- Robustețe
- Scalabilitate
- Flexibilitate

http://www-users.cs.york.ac.uk/jtimmis/utm/ais-course.html

Aplicații

1. Detecție anomalii și securitatea sistemelor informaționale;
2. Analiza datelor (clasificare, recunoaștere forme, clustering etc)
3. Planificare;
4. Căutare și optimizare;
5. Auto-organizare și control autonom;

Sistem imunitar natural

Specificul sistemului imunitar natural: două componente:

- Innăscut (moștenit de la părinți) – se bazează pe granulocite (neutrofile, eozinofile si bazofile) și celule macrofage

- Dobândit pe parcursul vietii – se bazeaza pe limfocite (celule B și celule T)

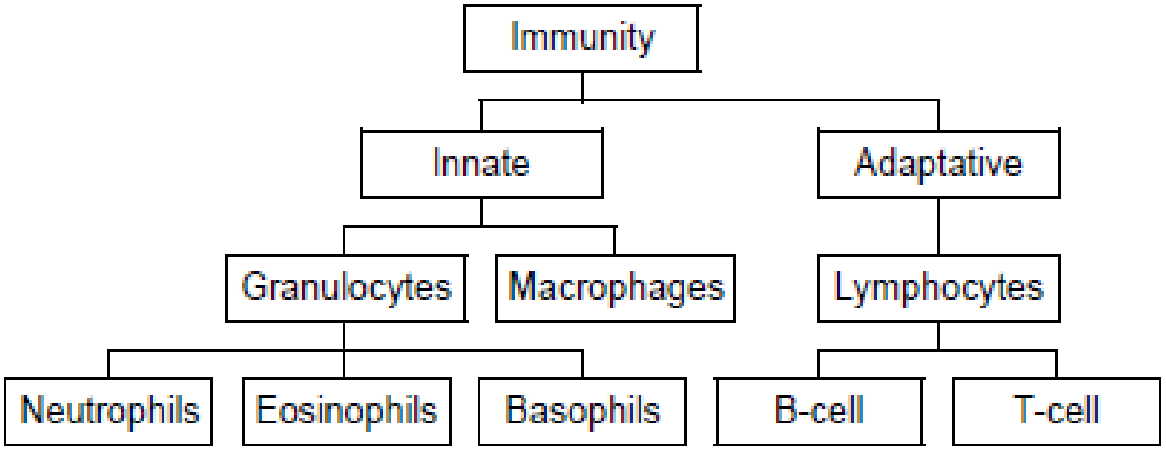

Sistem imunitar natural

Specificul sistemului imunitar natural

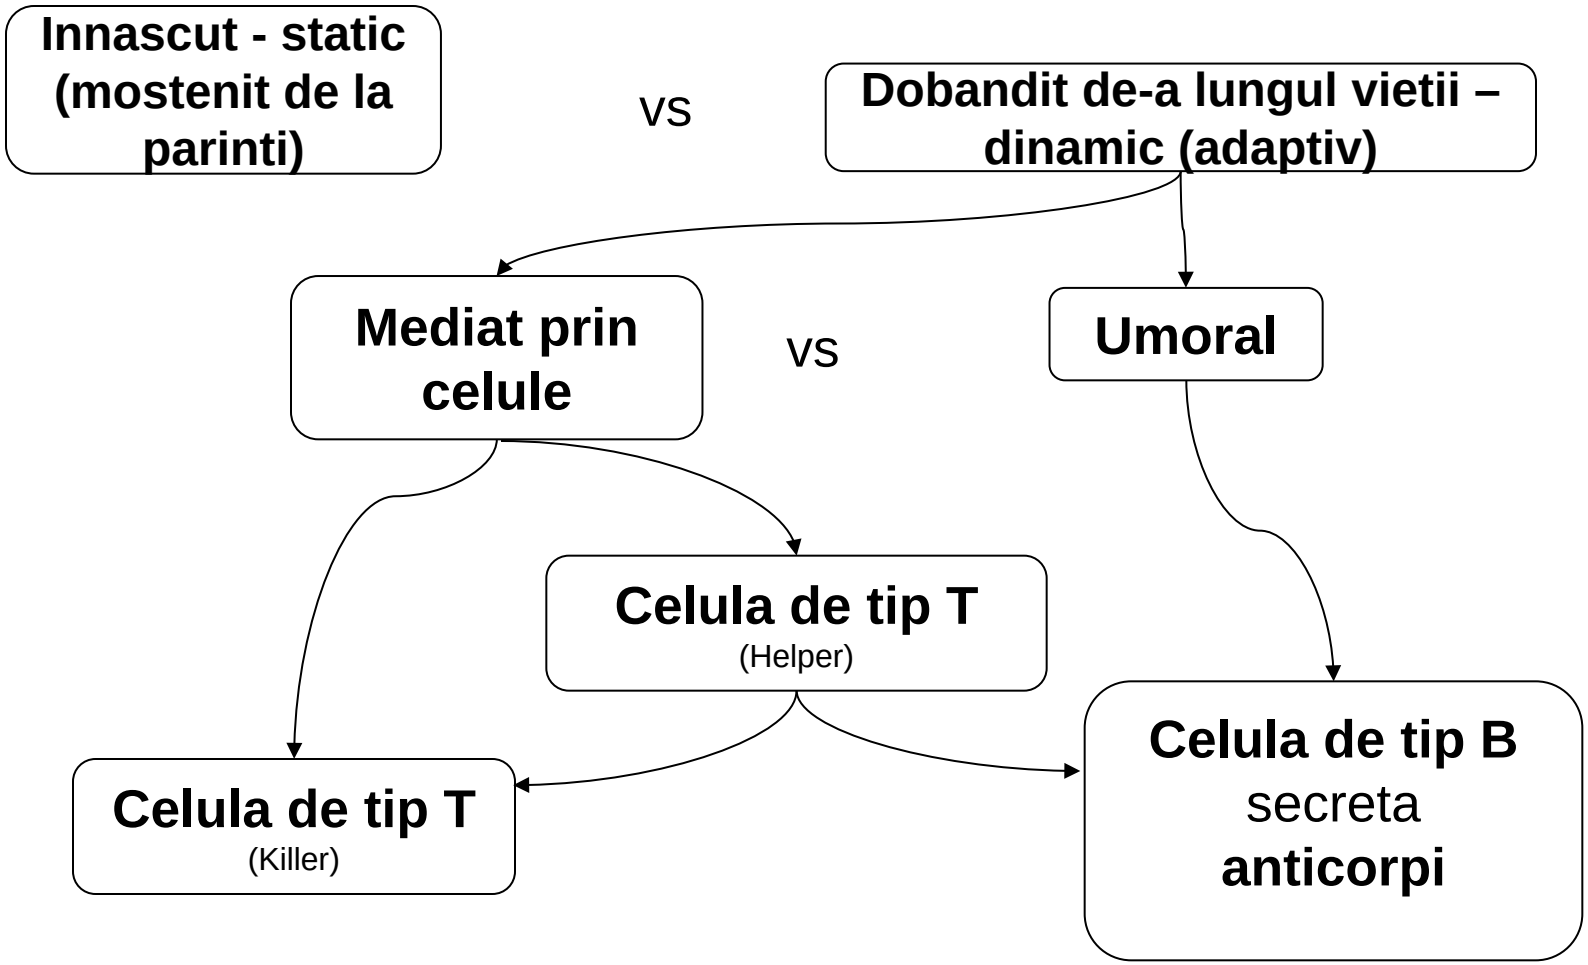

Sistem imunitar natural

Specificul sistemului imunitar natural – diferite nivele de acțiune

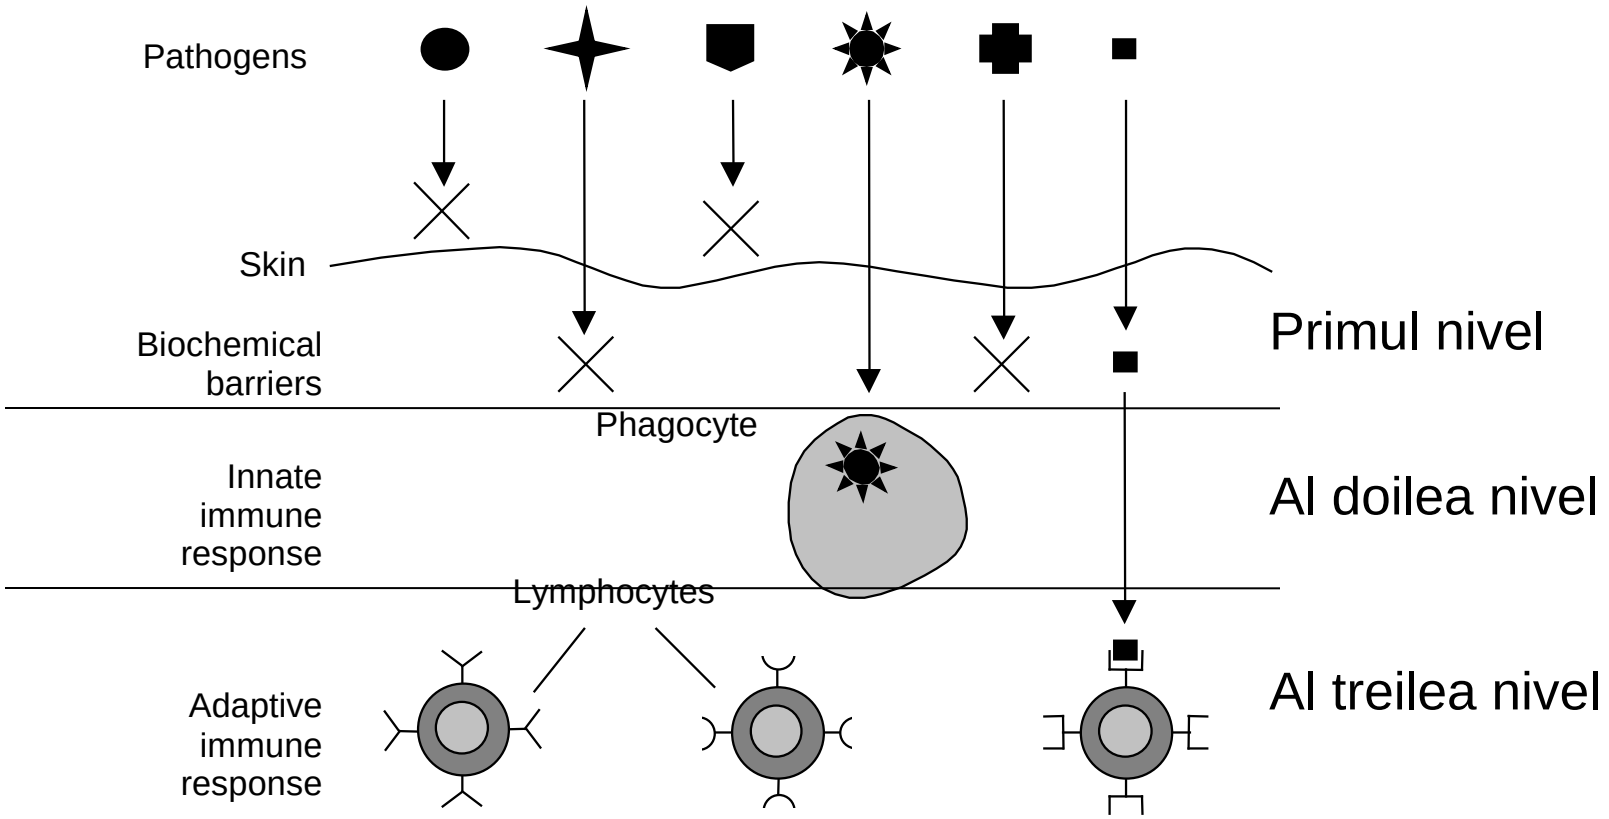

Sistem imunitar natural

Componenta adaptivă a sistemului imunitar (acționează la al treilea nivel) se caracterizează prin abilități de:

- Memorare (capacitatea de a-și “reaminti” de contactul anterior cu agenți patogeni și de a reacționa mai rapid la un nou contact)
- Invățare (capacitatea de a recunoaște agenți patogeni neîntâlniți anterior)

a) Elementele active: limfocite

- Conțin receptori specifici pentru recunoașterea antigenilor (organismele conțin un repertoriu de milioane de receptori)
- Sunt de două tipuri:
  - Celule de tip B
    - Sintetizate în măduva oaselor (bone marrow)
    - Contin receptori numiți anticorpi – recunoșterea se bazează pe complementaritatea între regiunea de legare (binding region sau paratop) a anticorpului și o regiune specifică a antigenului (epitop)
  - Celule de tip T: sintetizate de către glanda numita timus

Sistem imunitar natural

Mecanisme principale:

Selecție negativă: cenzurarea celulelor de tip T al căror rol este să identifice ce este propriu organismului (definesc comportamentul normal)

Selectie clonală: proliferarea și diferențierea celulelor care au recunoscut un antigen (învățare și generalizare)

Maturizarea afinității: afinitatea celulelor (de tip B) care au recunoscut un antigen este "întărită" prin

- Mutații asupra receptorilor (probabilitatea de mutație este invers proporțională cu afinitatea)
- Stocarea celulelor cu afinitate crescuta într-un "bazin" de celule cu memorie (celule B cu rol de memorie)
- Eliminarea celulelor cu comportament incorect

Sistem imunitar natural

Mecanisme principale:

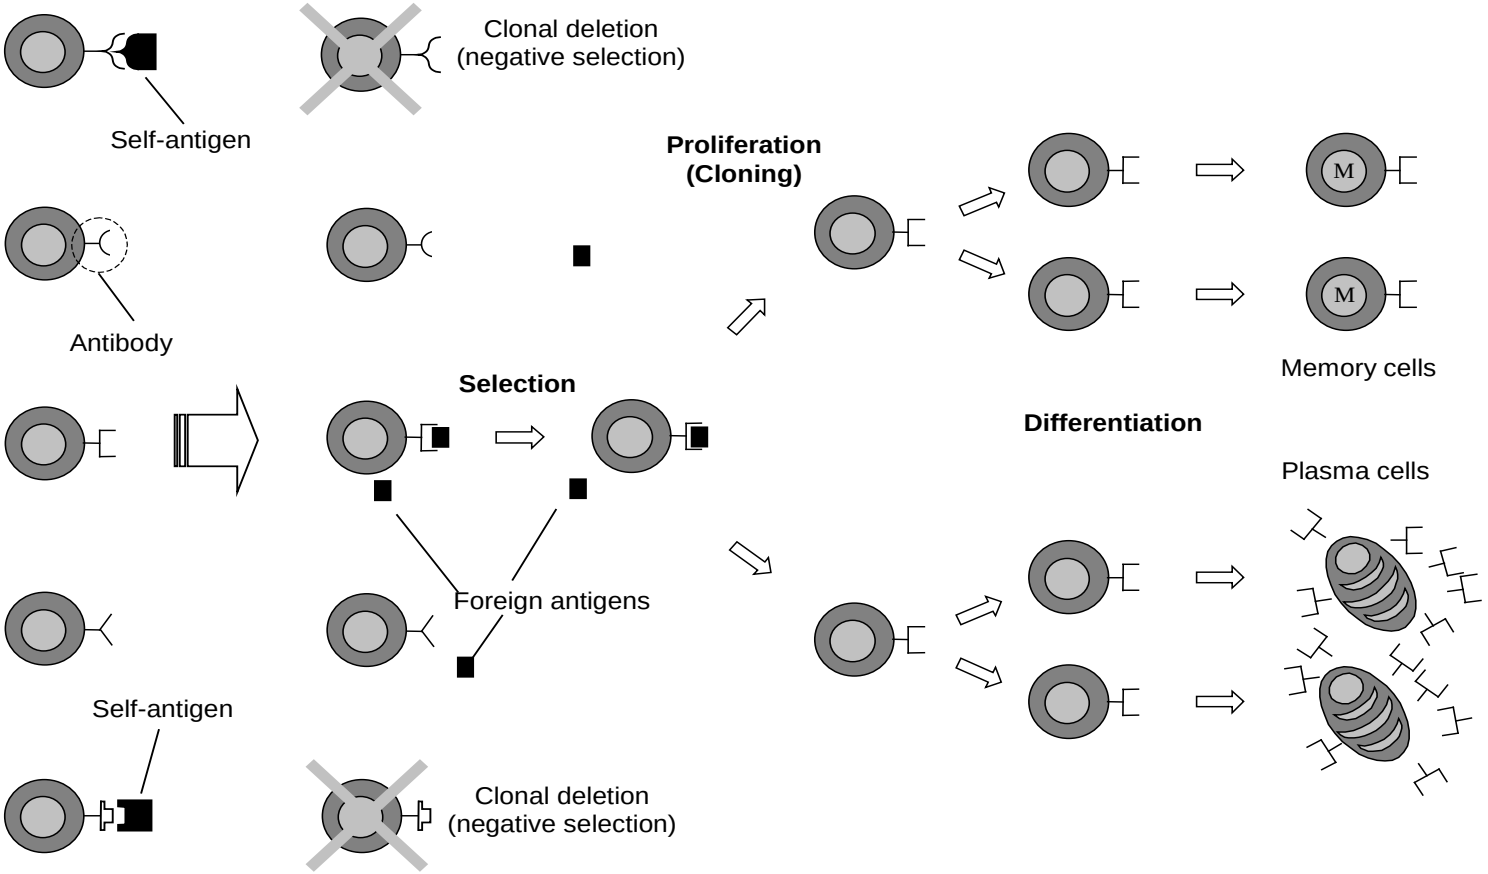

Sistem imunitar natural

Modul de acțiune al sistemului imunitar natural

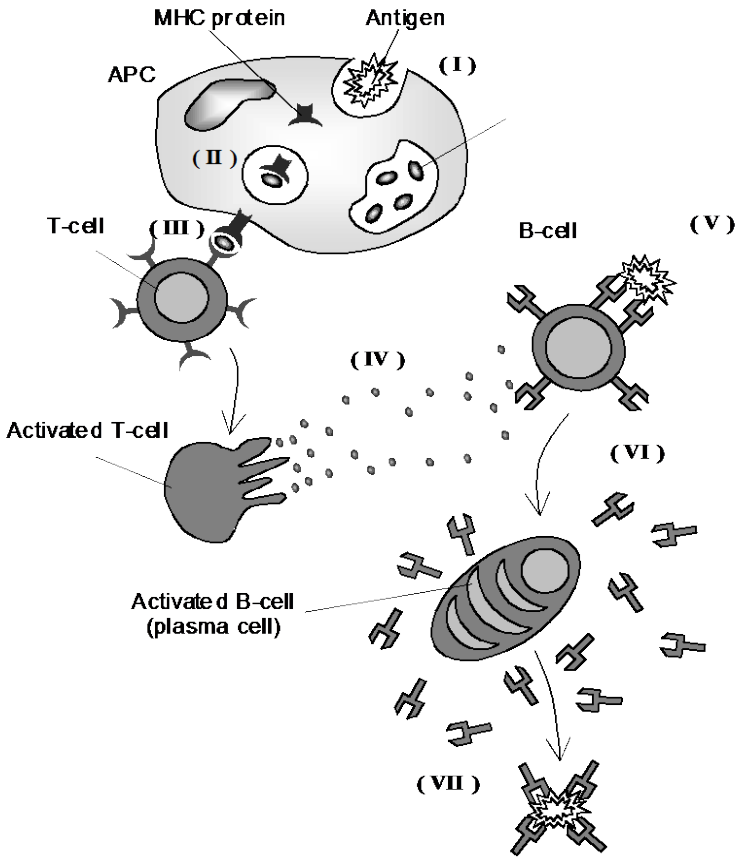

Sistem imunitar natural

Modul de acțiune al sistemului imunitar natural

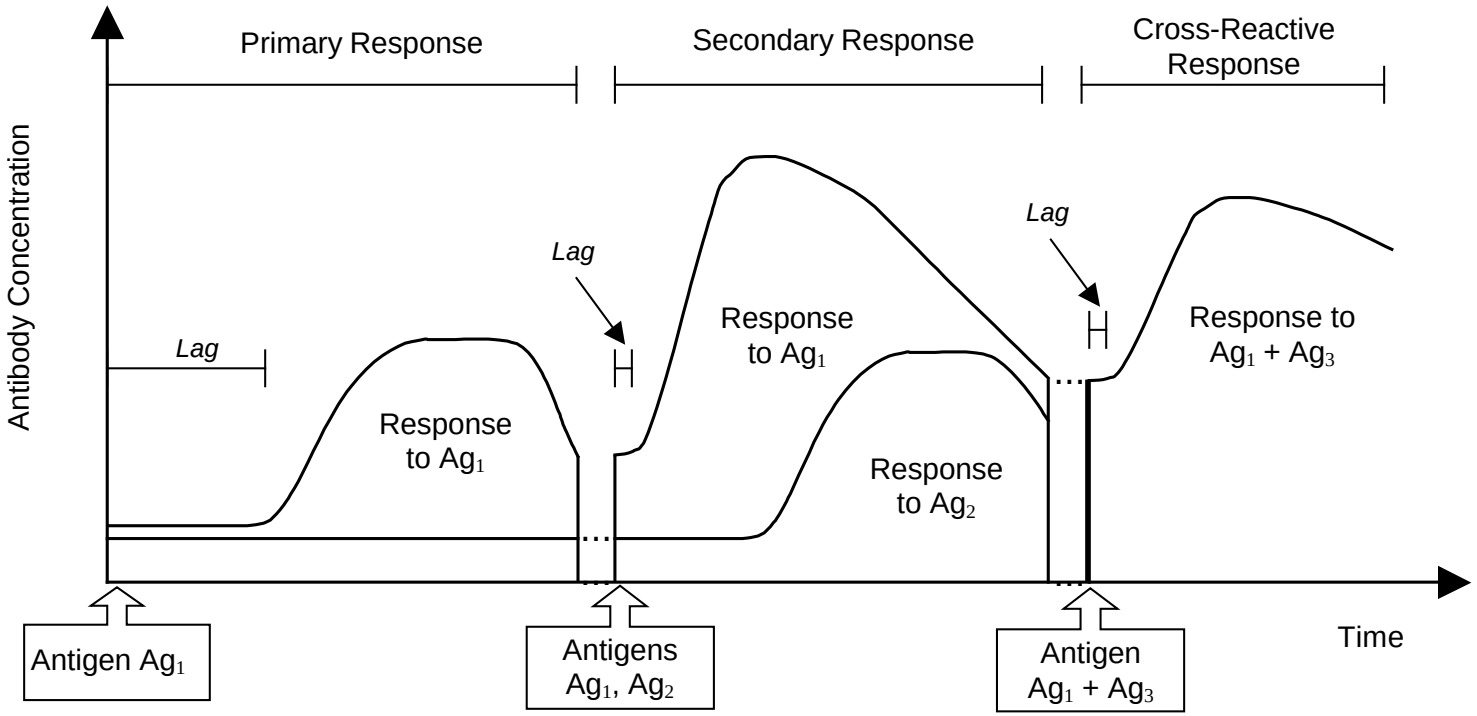

Reacție primară: primul răspuns la atacul unui antigen

Reacție secundară: reacție mai rapidă bazată pe rememorarea atacurilor anterioare

Sistem imunitar artificial

Principiul rezolvării problemelor cu AIS:

Problema de rezolvat = mediul in care este plasat organismul

Soluția problemei = antigen

Estimator al soluției (element al populației) = anticorp

Afinitate = măsură a calității unui estimator

Sistem imunitar artificial

Principiul rezolvării problemelor cu AIS[DeCastro, Timmis, 2002]

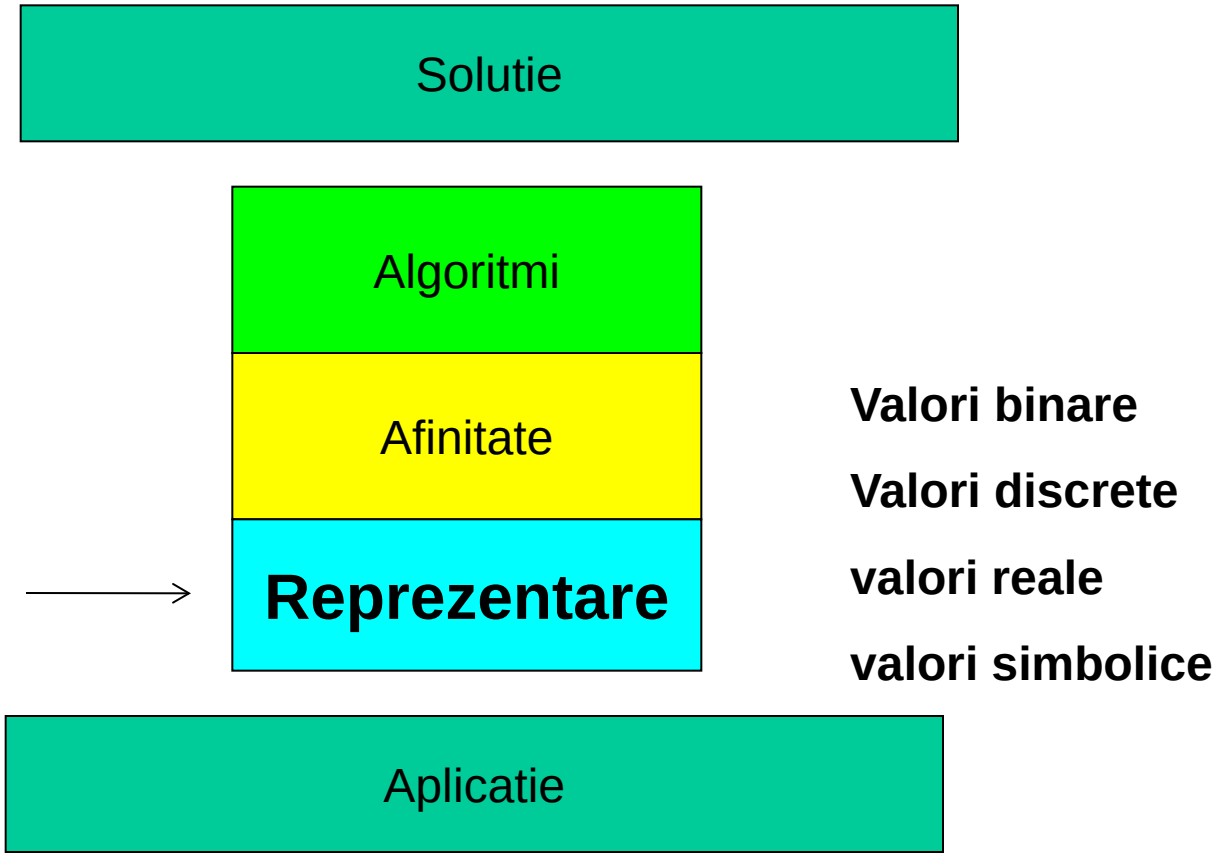

Sistem imunitar artificial

Principiul rezolvarii problemelor cu AIS[DeCastro, Timmis, 2002]

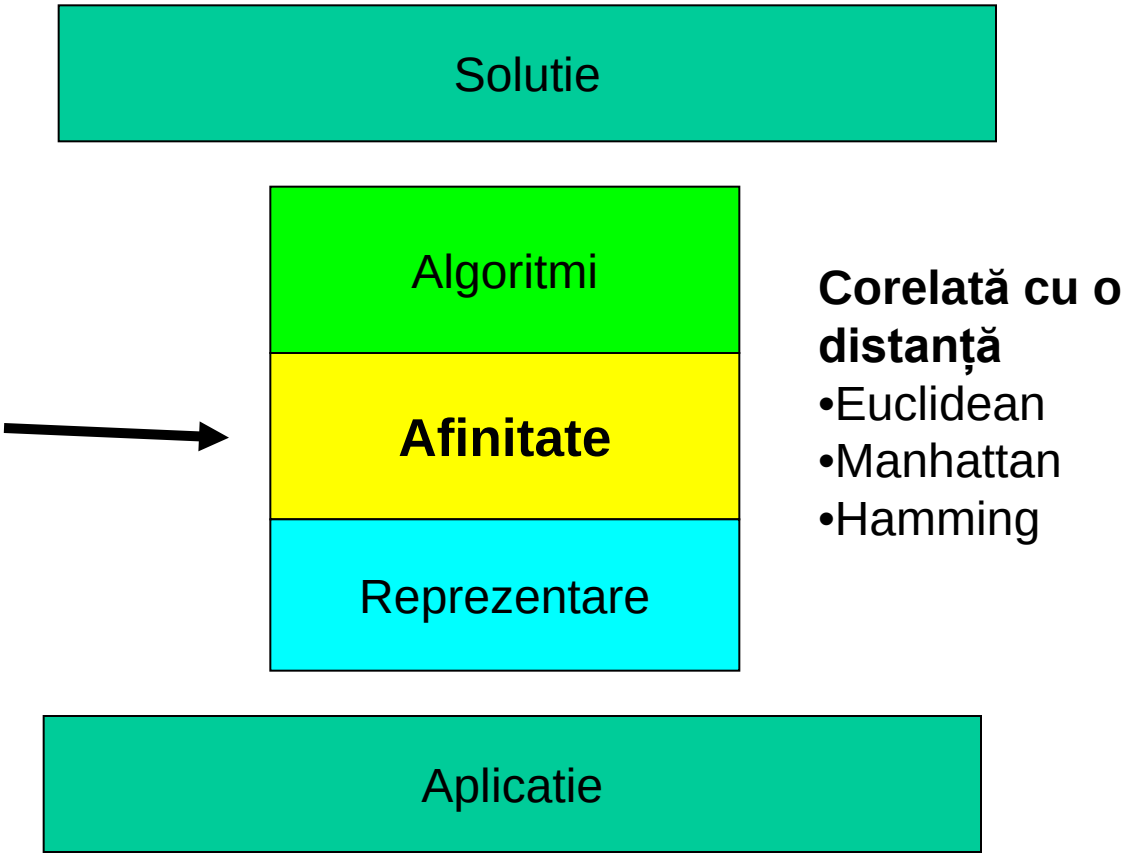

Sistem imunitar artificial

Principiul rezolvarii problemelor cu AIS [DeCastro, Timmis, 2002]

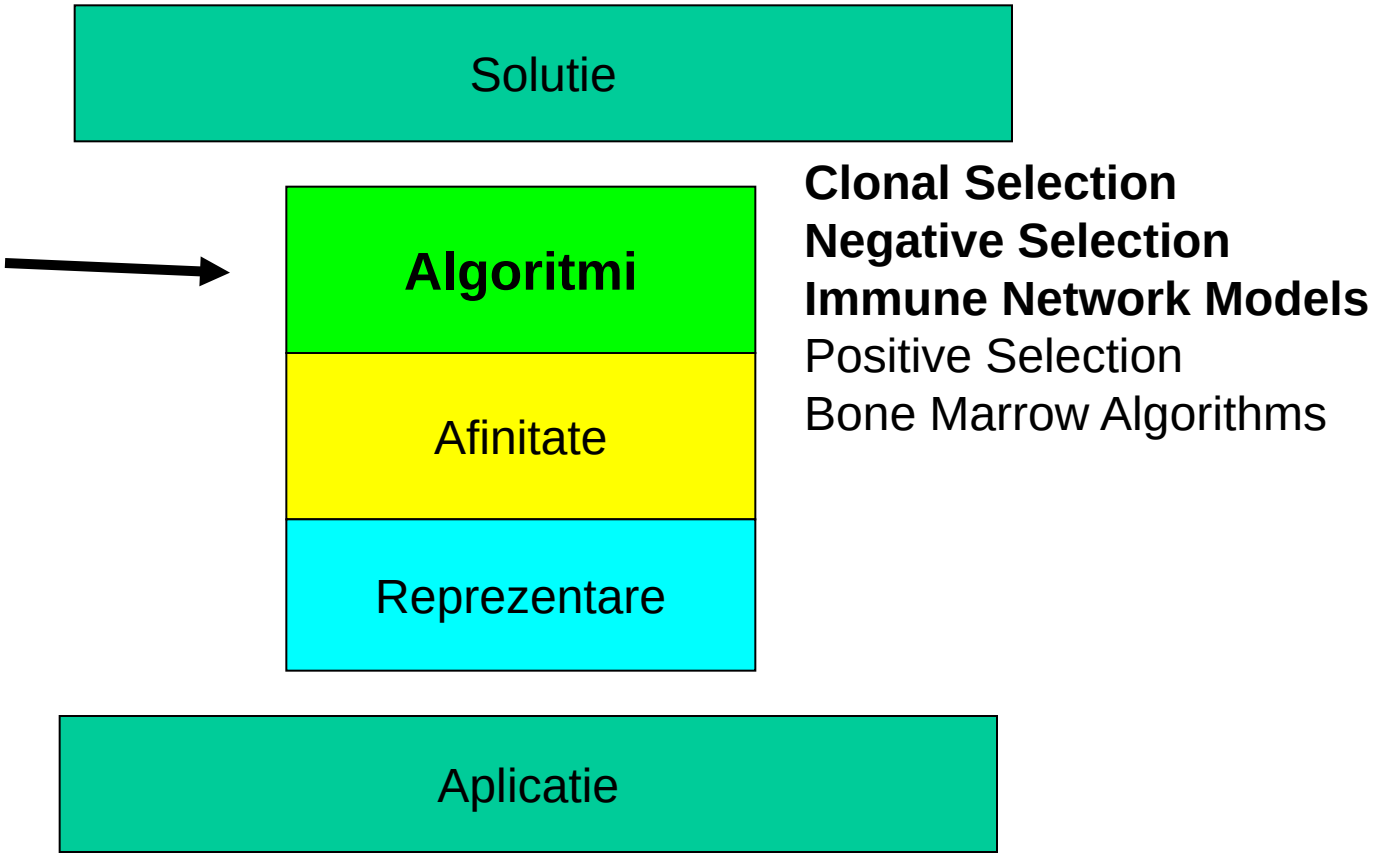

Sistem imunitar artificial

Algoritmul CLONALG (Selecție clonală)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinității)
b. Clonal selection and expansion (selecție clonală și multiplicare)
c. Affinity maturation (maturizarea afinității)
d. Metadynamics (modificare prin mutație aleatoare)

UNTIL “conditie de oprire”

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

- Creează o populație de indivizi (anticorpi)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinității)

b. Clonal selection and expansion (selecție clonală și multiplicare)

c. Affinity maturation (maturizarea afinității)

d. Metadynamics (modificare prin mutație aleatoare)

UNTIL “conditie de oprire”

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinității)

b. Clonal selection and expansion (selecție clonala si multiplicare)

c. Affinity maturation (maturizarea afinitatii)

d. Metadynamics (modificare prin mutatie aleatoare)

UNTIL “conditie de oprire”

Pentru fiecare șablon antigenic (dată din setul de intrare sau element al populației) se efectuează prelucrările a-d

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinității)

b. Clonal selection and expansion (selecție clonală și multiplicare)

c. Affinity maturation (maturizarea afinității)

d. Metadynamics (modificare prin mutație aleatoare)

UNTIL “conditie de oprire”

Calculează afinitatea

a) Pb de analiză a datelor: afinitatea e cu atât mai mare cu cât similaritatea dintre data de intrare (antigen) și elementul populației (anticorp) este mai mare

b) Pb de optimizare: afinitatea e cu atât mai mare cu cat valoarea fitness-ului (corelată cu funcția obiectiv) este mai mare

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinitatii)

b. Clonal selection and expansion (selectie clonala si multiplicare)

c. Affinity maturation (maturizarea afinitatii)

d. Metadynamics (modificare prin mutatie aleatoare)

UNTIL “conditie de oprire”

- Selectează n elemente din P în ordinea descrescatoare a afinității
- Genereaza pt. fiecare element selectat din P un număr de clone direct proporțional cu afinitatea.

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinitatii)

b. Clonal selection and expansion (selectie clonala si multiplicare)

c. Affinity maturation (maturizarea afinității)

d. Metadynamics (modificare prin mutație aleatoare)

UNTIL “conditie de oprire”

- Aplică mutație fiecărei clone
- Rata de mutație e invers proporțională cu afinitatea
- Se adaugă indivizii obtinuți prin mutație la populație
- Se evaluează afinitatea pentru indivizii adăugați și cel cu afinitatea maximă este memorat

Sistem imunitar artificial

Algoritmul CLONALG (Selectie clonala)

Initializare

REPEAT

Antigenic presentation (contact cu antigenul)

a. Affinity evaluation (evaluarea afinitatii)

b. Clonal selection and expansion (selectie clonala si multiplicare)

c. Affinity maturation (maturizarea afinitatii)

d. Metadynamics (modificare prin mutatie aleatoare)

UNTIL "conditie d

- O parte dintre indivizii cu afinitate mică sunt înlocuiți cu elemente generate aleator

Sistem imunitar artificial

Aplicații ale algoritmului CLONALG (Selecție clonală)

- Recunoaștere forme = generare “detectori” pentru recunoașterea unor simboluri reprezentate prin bitmap-uri

Obs: afinitatea se măsoară folosind distanța Hamming

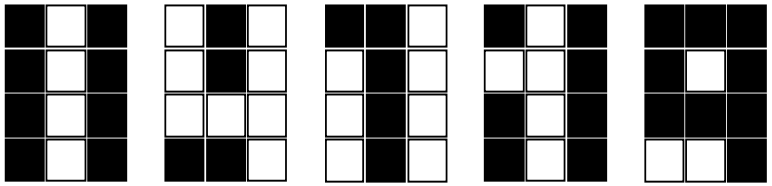

$$\mathbf{P} = \begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ p_4 \\ p_5 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 1 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 0 \\ 1 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 1 \\ 1 & 1 & 1 & 1 & 0 & 1 & 1 & 1 & 1 & 0 & 0 & 1 \end{bmatrix}$$

Sistem imunitar artificial

Aplicatii ale algoritmului CLONALG (Selectie clonala)

- Optimizare multi-modală = identificarea tuturor optimelor (globale și locale) ale unei funcții

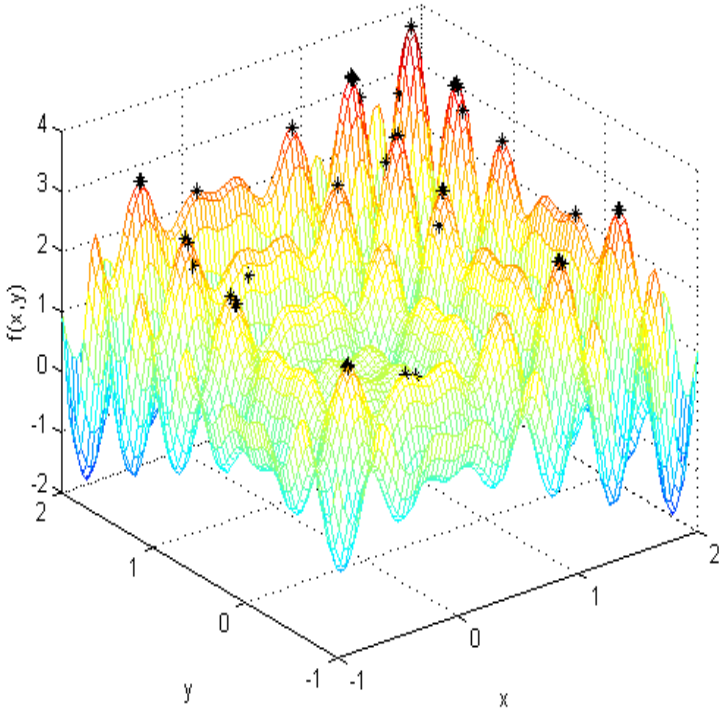

Sistem imunitar artificial

Proprietăți ale algoritmului CLONALG (Selecție clonală)

- Structura generală este similară cu cea a unui algoritm evolutiv (în ipoteza că rolul fitness-ului este transferat măsurii de afinitate)

- Elementele specifice se referă la:
  - Procesul de clonare controlat de valoarea afinității
  - Probabilitatea de mutație este invers proporțională cu valoarea afinității
  - Elementele cu afinitate mică sunt înlocuite cu elemente aleatoare

Sistem imunitar artificial

Algoritm de selecție negativă

- Se bazează pe principiul discriminării dintre propriu (self) și străin (non-self)
- Elementele de tip “propriu” se consideră ca fiind reprezentări ale comportamentului normal al unui sistem – aceste reprezentări formează un set S
- Scopul algoritmului este să genereze un set de detectori D care nu se potrivesc cu elementele din S (detectori ai elementelor străine – corespund unor comportamente anormale)
- Algoritmul monitorizează comportarea sistemului pentru a detecta apariția în S a unor elemente care se potrivesc cu detectorii din D - reprezintă semnalul unui comportament anormal al sistemului

Sistem imunitar artificial

Algoritm de selecție negativă

1. Generare set detectori

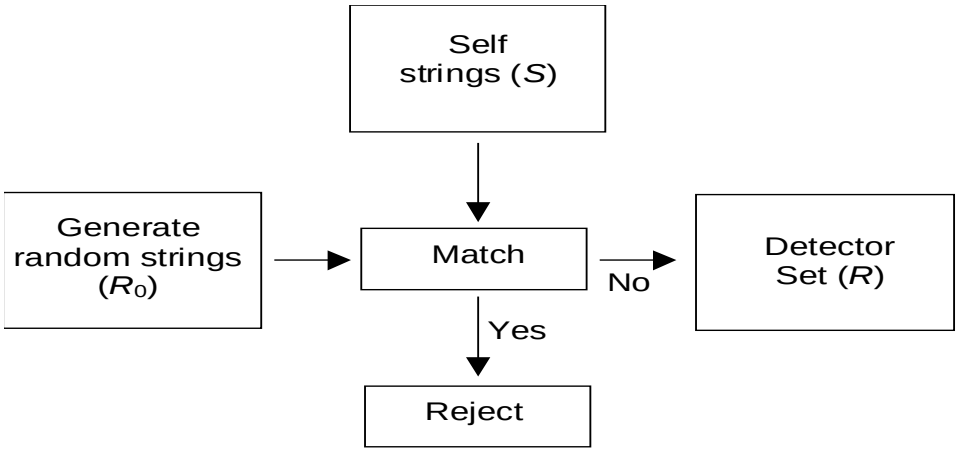

2. Monitorizare sistem

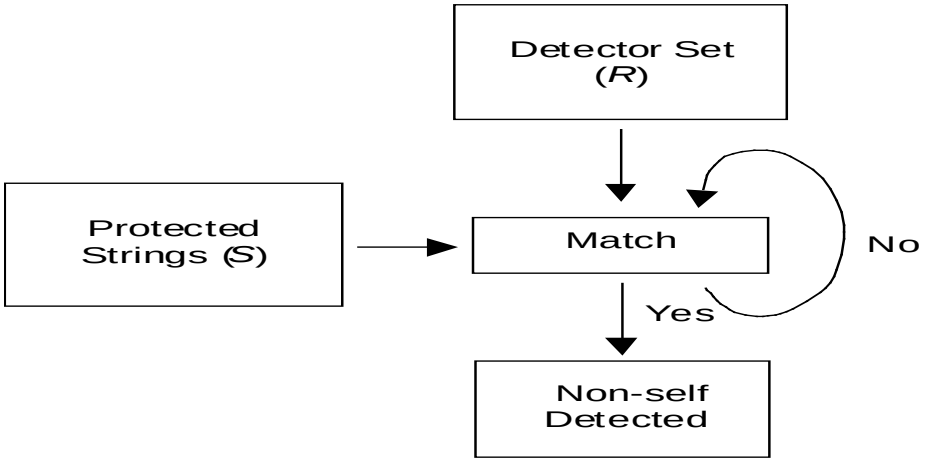

Aplicații: securitatea calculatoarelor (detecție intruși) – aplicabilitatea este totusi limitată

Sistem imunitar artificial

Algoritm de selecție negativă

input : S_{seen} = set of seen known self elements
output: D = set of generated detectors
begin
  repeat
    Randomly generate potential detectors and place them in a set P
    Determine the affinity of each member of P with each member of the self set S_{seen}
    If at least one element in S recognises a detector in P according to a recognition threshold, then the detector is rejected, otherwise it is added to the set of available detectors D
  until *Until stopping criteria has been met*
end

J.Timmis, P. Andrews, N. Owens, E. Clark – An Interdisciplinary Perspective of Artificial Immune Systems, Evolutionary Intelligence, Volume 1, Number 1, 5-26, 2008

Sistem imunitar artificial

Algoritmul aiNET

Initializare

REPEAT

- Antigenic presentation (contact cu antigenul)
  a. Affinity evaluation (evaluarea afinității)
  b. Clonal selection and expansion (selecție clonală și multiplicare)
  c. Affinity maturation (maturizarea afinității)
  d. Metadynamics (modificare prin mutație aleatoare)
  e. Clonal suppression (eliminarea clonelor cu afinitate mica)
- Network interactions (analiza interacțiunilor dintre anticorpii rețelei = calcul afinitate între perechi de anticorpi)
- Network suppression (eliminarea anticorpilor similari cu alți anticorpi)
- Diversity (introducerea unor anticorpi aleatori)

UNTIL “conditie de oprire”

Sistem imunitar artificial

Proprietati ale algoritmului aiNET:

- aiNET este in mare parte similar cu algoritmul CLONALG cu deosebirea ca utilizează un mecanism de supresie bazat pe afinitatea dintre elementele populatiei
- aiNET a fost initial utilizat pentru rezolvarea problemelor de grupare a datelor (ulterior s-a arătat ca are dificultati in gruparea datelor cu distribuție neuniformă)
- aiNET a fost aplicat cu succes in rezolvarea problemelor de optimizare multimodală

Sistem imunitar artificial

aiNET (analogia cu sistemul imunitar natural)

Sistem imunitar	**aiNET**
Anticorp	Dată internă (soluție potențială a problemei, model, element al populației)
Antigen	Data de antrenare
Afinitate	Măsură a calității unui element
Clonarea unei celule	Duplicarea datelor interne
Hipermutatie somatica	Mutație invers proportională cu afinitatea
Rețea imuna	Rețea de date interne
Metadinamica	Eliminarea/crearea unor date interne

http://www.aickelin.com

Sistem imunitar artificial

aiNET - aplicatii in clustering

Training Pattern

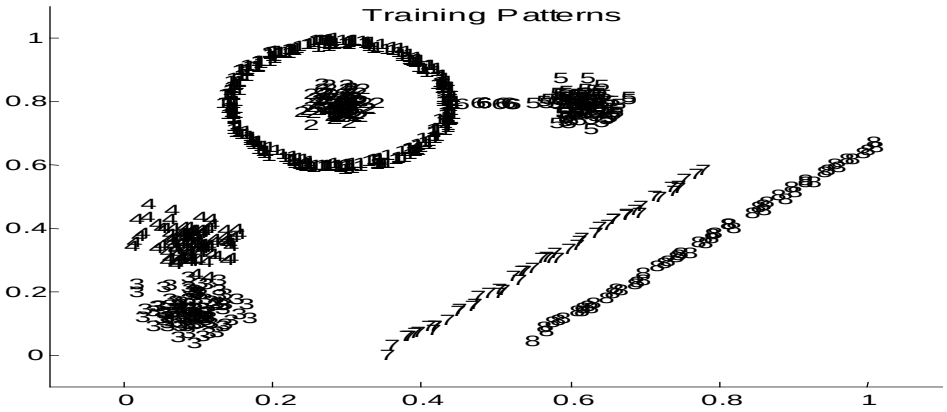

Result immune network

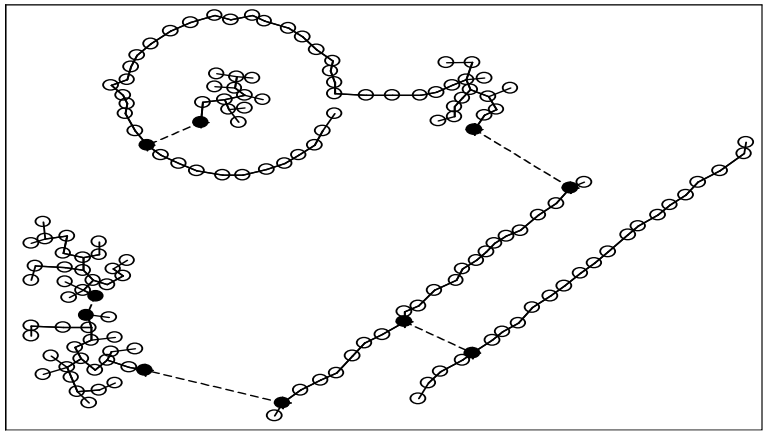

Sistem imunitar artificial

aiNET - optimizare multimodala

Populatie initiala

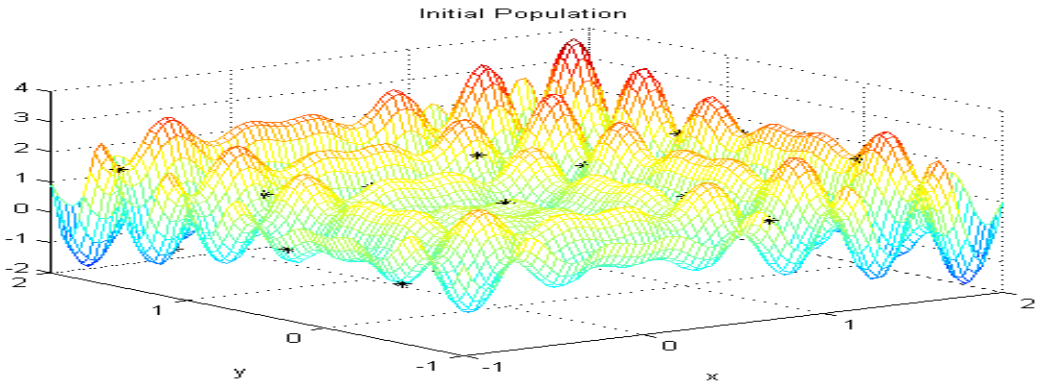

Populatie finala

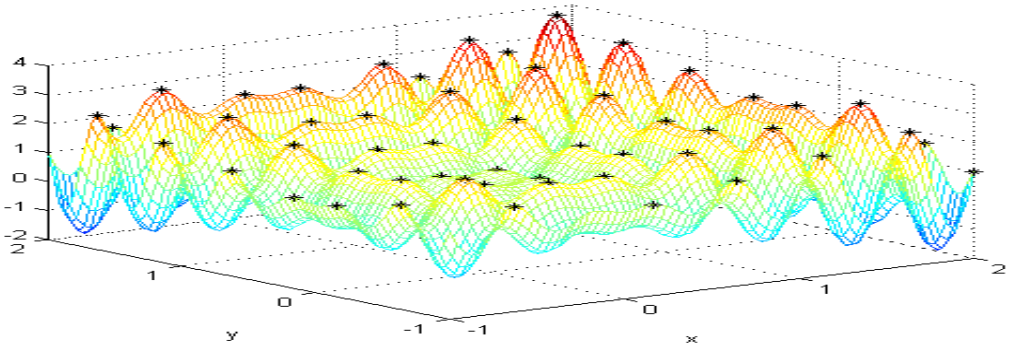

Sistem imunitar artificial

Comparatii cu alti algoritmi

	AG (Optimizare)	**RN (Clasificare)**	**AIS**
Componente	Cromozom	Neuron artificial	Sir de atribute
Locatia componentelor	Dinamica	Predefinita	Dinamica
Structura	Componente discrete	Retea de componente	Componente discrete/ retea de componente
Stocarea cunostintelor	Cromozom	Ponderile conexiunilor	Concentratia componentelor / Conexiunile retelei
Dinamica	Evolutie	Invatare	Evolutie/ Invatare
Metadinamica	Recrutare/ eliminare de componente	Adaugare/eliminare conexiuni	Recrutare/ eliminare de componente
Interactiunea intre componente	Incrucisare	Conexiuni sinaptice	Conexiuni
Interactiunea cu mediul	Functia fitness	Stimuli externi	Functie de recunoastere/ obiectiv
Prag de activare	Crowding / Sharing	Activarea neuronului	Afinitatea componentei

Bacterial Foraging Optimization

Creator: K. Passino (2002) – inițial ca instrument pentru control și optimizare distribuită

Sursa de inspirație : mecanismele de deplasare ale bacteriilor (ex: Escherichia Coli) cu scopul identificării regiunilor cu hrană (bacteria încearcă să maximizeze cantitatea de energie acumulată în unitatea de timp)

Mecanisme principale:

- Chemotaxis (deplasare)
- Swarming (grupare)
- Reproduction (reproducere)
- Elimination (eliminare)

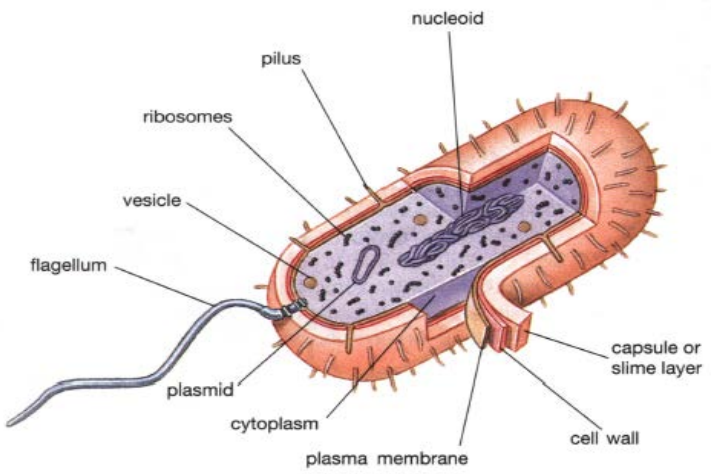

Bacterial Foraging Optimization

Structura generală:

Inițializarea populației de m bacterii (poziții inițiale stabilite aleator)

FOR l=1, Ne DO // etape de eliminare

  FOR k=1,Nr DO // etape de reproducere

    FOR j=1,Nc DO // etape de deplasare

      Chemotaxis (ajustare pozitie)

      Swarming (calcul termen de ajustare a functiei obiectiv)

      Evaluare elemente populatie

    ENDFOR

  Reproduction

 ENFOR

 Elimination

ENDFOR

Bacterial Foraging Optimization

Chemotaxis: bacteriile se deplasează cu ajutorul flagelului și efectuează două tipuri de mișcare:

- De avans (swim)
- Rostogolire cu caracter aleator (tumble)

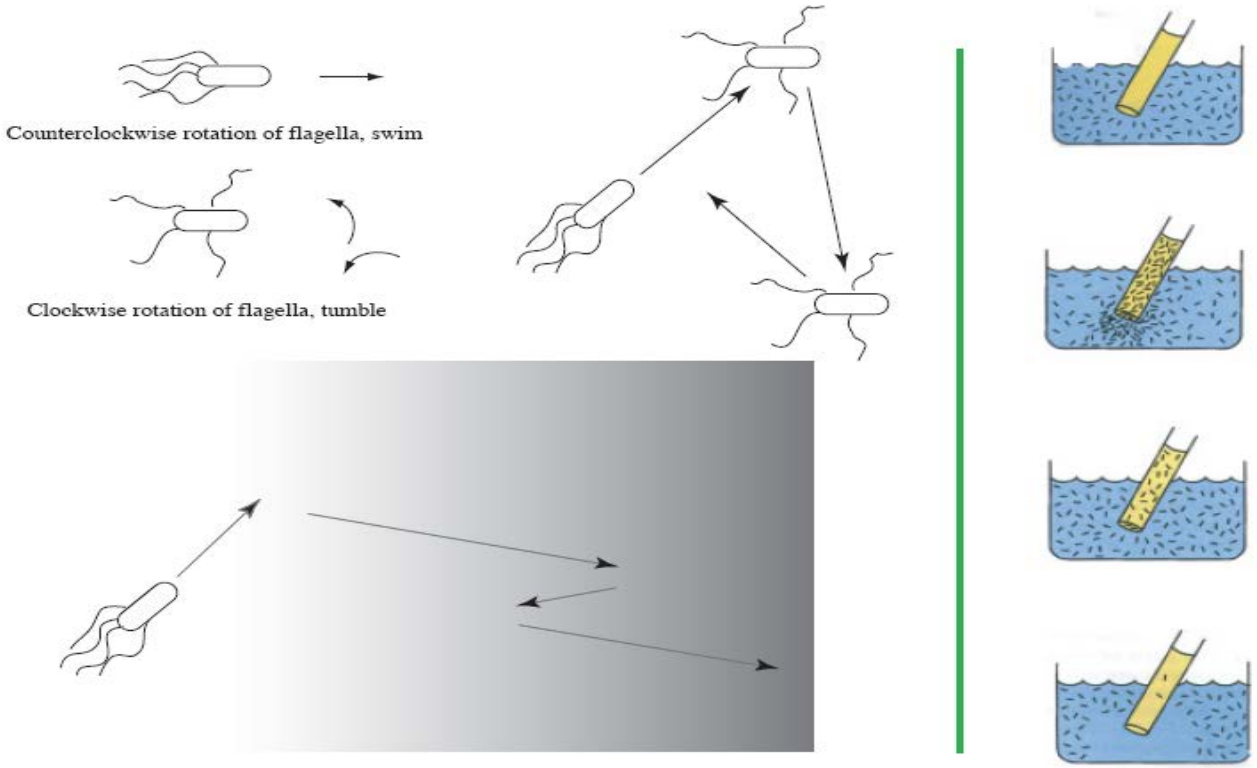

Bacterial Foraging Optimization

Chemotaxis: fiecare bacterie este caracterizată prin:

- Poziție (vector cu coordonate în spațiul de căutare – corespunde unei aproximări a soluției)
- Dimensiune pas deplasare pentru fiecare direcție (valoarea pasului de ajustare a fiecărei componente)

Actualizarea poziției bacteriei i la etapa j de mișcare, etapa k de reproducere și etapa l de eliminare:

$$p_i(j+1,k,l)=p_i(j,k,l)+C(i)\ d(i)$$

C(i) = număr pozitiv reprezentând dimensiunea pasului de deplasare

d(i) = vector de norma 1 având componente alese aleator

Bacterial Foraging Optimization

Swarming:

- modelează procesul prin care mai multe bacterii se grupează formând un inel care determină prin existența unei regiuni de densitate (concentrație) mai mare o reorganizare a mediului; o interpretare simplificatoare sugerează ca bacteriile grupate au șanse mai mari să ajungă în regiuni bogate în nutrienți
- impactul procesului biologic este modelat prin adăugarea la funcția obiectiv asociată problemei de optimizare (minimizare) care trebuie rezolvată a unui termen de forma:

$$J(p) = -\sum_{i=1}^{m} d_a \exp(-w_a \sum_{r=1}^{n} (p^r - p_i^r)^2) + \sum_{i=1}^{m} h_r \exp(-w_r \sum_{r=1}^{n} (p^r - p_i^r)^2)$$

Obs.

1. m=dimensiune populație; n=număr variabile; p=poziție arbitrară din spațiul de căutare, p_i = poziția bacteriei i, p^r = componenta r a poziției
2. d_a, w_a, h_r, w_r = parametri de control ai proceselor de atracție (a) respectiv respingere (r) între bacterii

Bacterial Foraging Optimization

Reproduction:

- Bacteriile mai putin sănătoase mor = elementele din populație de calitate slabă sunt eliminate (jumătatea mai puțin bună din populație se elimină)
- Bacteriile sănătoase se multiplică = elementele din populație de calitate bună sunt clonate (jumătatea bună din populație se clonează)

Elimination and Dispersal:

- Modificarea unor factori (de exemplu creșterea temperaturii) poate conduce la dispariția unor bacterii = elemente selectate aleator din populație sunt eliminate și inlocuite cu elemente generate aleator (pentru a păstra nemodificată dimensiunea populației)

Bacterial Foraging Optimization

Aplicații:

- Probleme de alocare dinamică a resurselor
- Optimizarea sistemelor de control
- Antrenarea rețelelor neuronale

Differential Evolution (DE)

Creatori: Rainer Storn & Kenneth Price (1995)

Scop: optimizare în domenii continue

Idee: pentru fiecare element al populației curente:

- se selectează aleator 3 elemente din populație
- Mutația se bazează pe calculul diferenței dintre două elemente alese aleator din populație și pe adăugarea diferenței înmulțită cu un factor de scalare la un alt element aleator din populație (această operație stă la originea denumirii metodei)
- elementul construit la etapa anterioară se încrucișează cu elementul curent
- dacă noul element obținut prin încrucișare este mai bun decât elementul curent atunci îl inlocuiește

Structura generală: identică cu cea a strategiilor evolutive

Differential Evolution (DE)

Problema: maximizare $f:D \subset R^n \rightarrow R$

$X = \{x_1, \ldots, x_m\}$ – populatie curenta

$Y = \{y_1, \ldots, y_m\}$ – populatie de candidati

$Z = \{z_1, \ldots, z_m\}$ – populatie noua

$$y_i^j = \begin{cases} x_{r_1}^j + F \cdot (x_{r_2}^j - x_{r_3}^j), & \text{cu probabilitatea } p \\ x_i^j, & \text{cu probabilitatea } 1-p \end{cases}$$

$r_1, r_2, r_3 = \text{indici aleatori din } \{1, \ldots, m\}$

$F \in (0,2], \; p \in (0,1]$

$$z_i = \begin{cases} x_i, & f(x_i) > f(y_i) \\ y_i, & f(x_i) \leq f(y_i) \end{cases}$$

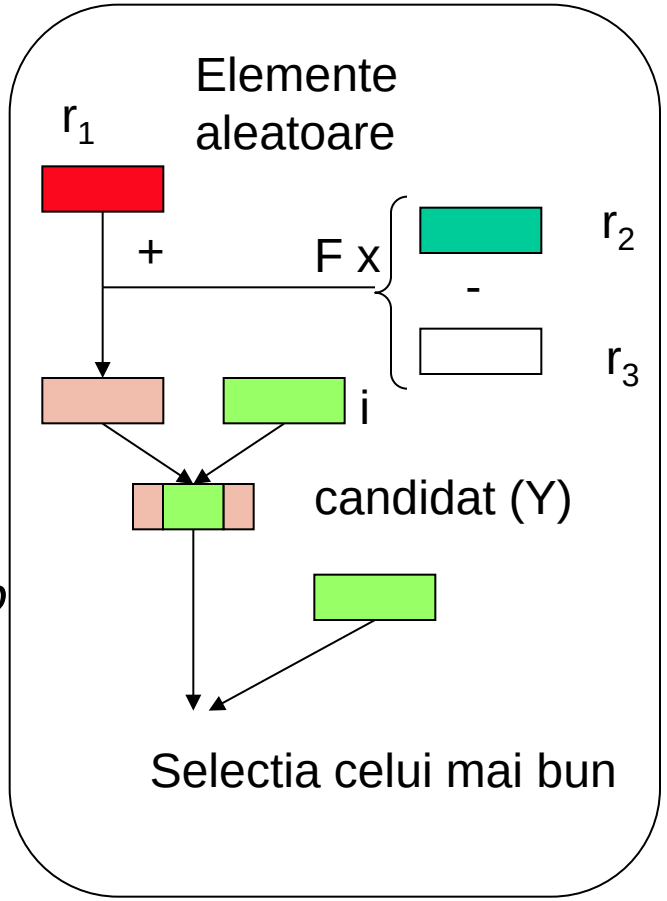

Differential Evolution (DE)

Variante

$$y_i^j = \begin{cases} x_{r_1}^j + F \cdot (x_{r_2}^j - x_{r_3}^j) \cdot N(0,1), & \text{cu probabilitatea } p \\ x_i^j, & \text{cu probabilitatea } 1-p \end{cases}$$

$$y_i^j = \begin{cases} x_{r_1}^j + F_1 \cdot (x_{r_2}^j - x_{r_3}^j) + F_2 \cdot (x_{r_4}^j - x_{r_5}^j), & \text{cu probabilitatea } p \\ x_i^j, & \text{cu probabilitatea } 1-p \end{cases}$$

$$y_i^j = \begin{cases} \lambda x_*^j + (1-\lambda) x_{r_1}^j + F \cdot (x_{r_2}^j - x_{r_3}^j), & \text{cu probabilitatea } p \\ x_i^j, & \text{cu probabilitatea } 1-p \end{cases}$$

x_* = cel mai bun element al populatiei

Taxonomie: DE/element de bază/număr de diferențe/tip de încrucișare

(e.g. DE/rand/1/bin, DE/rand/2/bin, DE/best/1/bin etc.)

Differential Evolution (DE)

Parametri de control:

Factor de scalare (F):

- domeniu de valori: (0,2)
- valori mici: efect de căutare locală;
  pot conduce la situații de convergență prematură
- valori mari: efect de căutare globală

Probabilitate de încrucișare:

- valori mici (<0.5): adecvate pt probleme separabile (optimizarea se poate realiza separat pe componente)
- valori mari (>0.5): adecvate pentru probleme neliniar separabile

Differential Evolution (DE)

Auto-adaptare [Brest, 2006]

- Se extinde fiecare element al populației cu două componente, una corespunzătoare factorului de scalare iar cealaltă corespunzătoare probabilității de încrucișare

- La fiecare generație parametrii se aleg uniform aleator în intervalul corespunzator

Aplicații:

- optimizare globală, multicriterială, multimodală
- Analiza datelor (clustering, reguli de clasificare)
- Planificare activități (grid scheduling)
- Prelucrarea imaginilor

Harmony Search (HS)

Sursa de inspirație: modul de ajustare a tonalităților în compoziția muzicală (Geem, 2001)

Structura generală: similară cu structura de la DE

Element specific: modul de construire al unui nou element

$$y_i^j = \begin{cases} x_r^j + bw(j) \cdot U_3 & \text{daca } U_1 < p_1 \text{ si } U_2 < p_2 \\ x_r^j & \text{daca } U_1 < p_1 \text{ si } U_2 \geq p_2 \\ U(a_j, b_j) & \text{altfel} \end{cases}$$

Semnificație notații:

- r = index aleator din {1,2...m,} (m= dim populație)
- U1,U2: variabile aleatoare uniform repartizate în [0,1]
- U3 : variabilă aleatoare uniform repartizată în [-1,1]
- bw(j) = stdev(X(j)) (abatere standard a valorilor componentei j)
- p1, p2: parametri control (ex: p1=0.9, p2=0.75)

Probabilistic Model Building Algorithms

Specific: reprezintă o clasă de algoritmi care realizează căutarea soluției prin simularea unor distribuții de probabilitate

Alte denumiri/variante:

- Estimation of Distribution Algorithms (EDA) [Mühlenbein & Paass, 1996]
- Iterated Density Estimation Algorithms (IDEA) [Bosman & Thierens, 2000]
- Bayesian Optimization Algorithms (BOA) [Pelikan, Goldberg, & Cantu-paz, 1998]

Idee: se înlocuiește mutația și încrucișarea cu un proces de estimare a unei distribuții de probabilitate a elementelor selectate iar noile elemente sunt generate prin simulare în conformitate cu acea distribuție de probabilitate

Observație: în felul acesta se exploatează distribuția elementelor promițătoare din populație

Probabilistic Model Building Algorithms

Ilustrarea ideii [M.Pelikan – Probabilistic Model Building GA Tutorial]

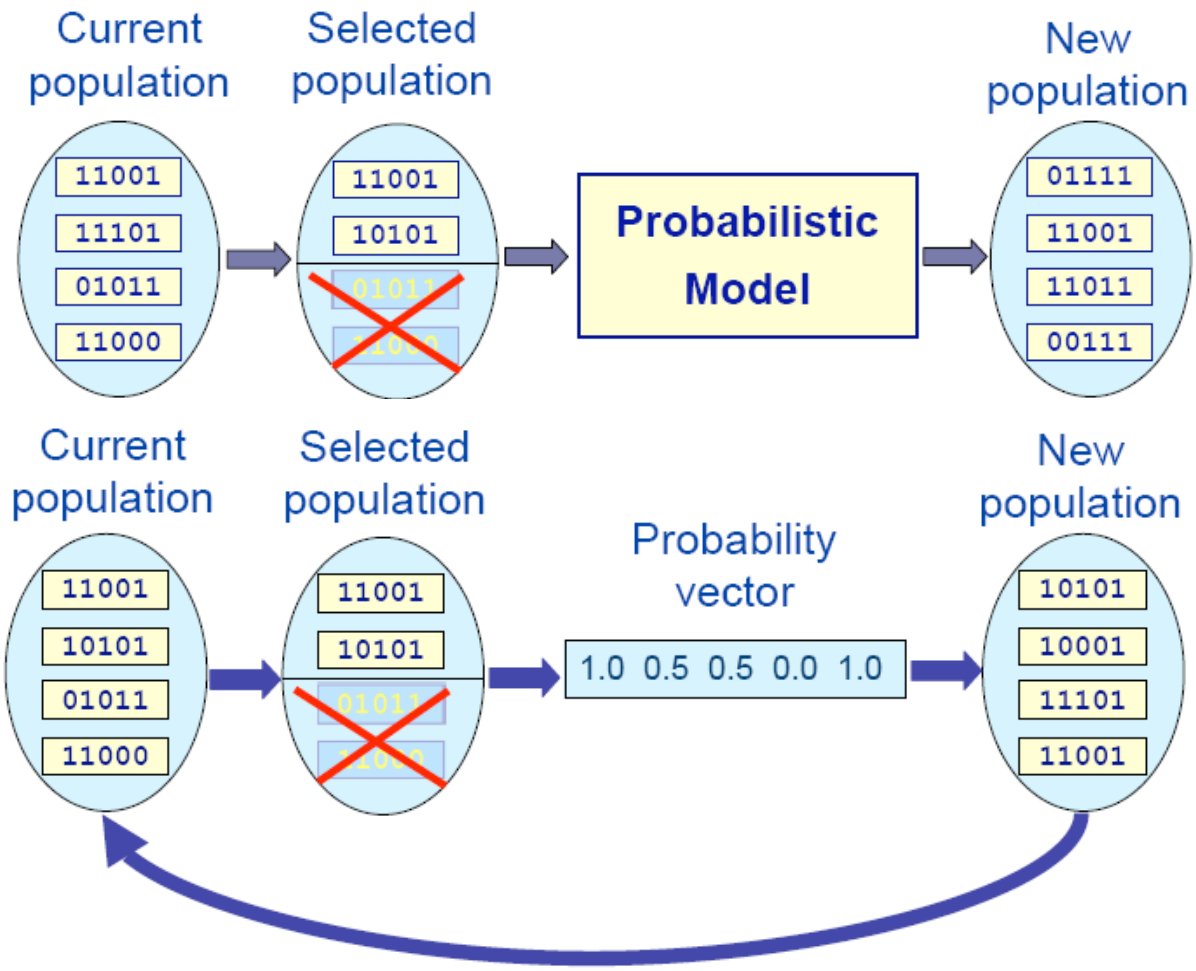

Probabilistic Model Building Algorithms

Structura generală.

Pas 1: Inițializarea populatiei (m elemente)

Pas 2: REPEAT

- selectează m'<m elemente din populația curentă (în funcție de calitatea lor)
- estimează o distribuție de probabilitate folosind elementele selectate
- generează m elemente în conformitate cu distribuția de probabilitate estimată

UNTIL <conditie de oprire>

Probabilistic Model Building Algorithms

Observații:

- Dificultatea principală constă în estimarea distribuției, în special în cazul în care componentele elementelor (variabilele funcției obiectiv) sunt corelate

- Pentru simplificare se poate presupune ca variabilele sunt independente; în acest caz probabilitatile corespunzatoare lor pot fi estimate independent

Variante de algoritmi bazate pe ipoteza independenței:

- UMDA (Univariate Marginal Distribution Algorithm)
- PBIL (Probabilistic Based Incremental Learning)

Probabilistic Model Building Algorithms

UMDA (Mühlenbein, Paass, 1996)

$$P^t(x_i) = \frac{\sum_{j=1}^{m'} \delta_j(X_i = x_i \mid S(t-1))}{m'}$$ probabilitatea corespunzatoare componentei i

$S(t\text{-}1)$ este populatia selectata la iteratia $(t\text{-}1)$

$\delta_j(X_i = x_i \mid S(t-1)) = 1$ daca al j-lea element selectat contine valoarea x_i pe componenta i

PBIL (Baluja, 1995)

$$P^t(x_i) = (1-\alpha)P^{(t-1)}(x_i) + \alpha \frac{\sum_{j=1}^{m'} \delta_j(X_i = x_i \mid S(t-1))}{m'}$$

$\alpha \in (0,1]$

Tabu Search

Creator: Fred Glover (1986)

Scop: metodă de rezolvare a problemelor de optimizare combinatorială

Specific:

- Tehnică iterativă de căutare locală bazată pe explorarea vecinătății configurației curente (vecinătatea unei configurații se definește ca fiind mulțimea configurațiilor ce pot fi atinse printr-o singură transformare; transformările posibile sunt specifice problemei)

- Utilizează o listă de configurații interzise care nu vor putea fi vizitate în următoarele iterații; lista tabu are o dimensiune limitată (implementată ca listă circulară)

Tabu Search

Structura generală:

Pas 1: se construiește o configurație inițială

Pas 2: REPEAT

- Se selectează cel mai bun element din vecinătatea configurației curente care este acceptabil în raport cu lista tabu
- Dacă elementul selectat este suficient de bun atunci se adaugă la o arhiva cu elite
- Se actualizează lista tabu

UNTIL <conditie de oprire>

Obs:

1. Daca vecinătatea unei configurații este prea mare atunci nu se evaluează toate elementele ci doar o selecție a acestora
2. Pentru îmbunătățirea funcționării, periodic se pot aplica etape de intensificare și diversificare a căutarii

Tabu Search

Intensificare:

Scop: exploatarea regiunilor ce par promițătoare

Mod de implementare:

- Se contorizează pentru fiecare componentă a configurației curente numărul de iterații consecutive în care a rămas nemodificată
- Se restartează procesul de căutare pornind de la cea mai bună configurație întâlnită considerând fixate componentele cu comportare bună (pentru care contorul are valori mari)

Tabu Search

Diversificare:

Scop: explorarea regiunilor ce nu au fost vizitate

Mod de implementare:

- Se contorizează frecvența de utilizare, pe parcursul intregului proces iterativ, a valorilor corespunzătoare diferitelor componente
- Se restartează procesul de căutare de la configurații in care sunt plasate componente cu frecvența mică de utilizare; sau se penalizeaza scorul unei configurații folosind frecvențele asociate componentelor; relaxarea restricțiilor prin modificarea sistematică (creștere urmată de descreștere și invers) a ponderilor utilizate în funcția obiectiv care include restrictiile (construită prin tehnica penalizării)

Memetic Algorithms

Creator: Pablo Moscato (1989)

Specific: hibridizarea algoritmilor evolutivi cu tehnici de cautare locala cu scopul de a introduce in metoda cunostinte specifice problemei de rezolvat

Denumire: “memetic” provine de la “meme” un termen introdus de Richard Dawkins pentru a desemna “unitatea de transmitere a diferitelor entitati (biologice, culturale, materiale) între generații”

Variante: Hybrid Evolutionary Algorithms, Baldwinian Evolutionary Algorithms, Lamarckian Evolutionary Algorithms, Cultural Algorithms or Genetic Local Search

Memetic Algorithms

Structura generală:

Pas 1: Inițializarea populatiei

Pas 2: WHILE <condiție de continuare>

- evaluează elementele populației
- generează noi elemente aplicând operatorii de evoluție (de exemplu încrucișare și mutație)
- selectează o subpopulație asupra căreia se aplică operatori specifici de căutare locală (de exemplu Simulated Annealing sau Tabu Search)

Observatii:

1. Căutarea locală se poate baza pe o colecție de algoritmi dintre care se alege la fiecare etapă câte un algoritm (în manieră aleatoare)
2. Elementele ce definesc operatorii de căutare locala pot face parte din componentele populației și pot fi transformate în procesul de evoluție