

An Adaptive Artificial Immune Network for Supervised Classification of Multi-/Hyperspectral Remote Sensing Imagery

*Yanfei Zhong, Member, IEEE, and
Liangpei Zhang, Senior Member, IEEE*

Clasificación hyperspectral

- Minimum Distance (MD)
- Gaussian maximum likelihood (GML)
- Mahalanobis distance
- Spectral Angle Mapper (SAM)
- The *k-nearest neighbor*
- *Decision Trees*
- *Artificial Neural Networks*
- Genetic algorithms
- Ant Colony Algorithm
- Recently developed support vector machine classifier

Artificial Inmune Network

- Inspirado en el sistema inmunitario de los seres vivos.
- Consiste en crear capas para defenderse de los patógenos.
- Se busca el antígeno que más se parezca al patógeno y se clona para defenderse de él.
- Los clones mutan para atacar mejor al antígeno.
- Finalmente guardan en memoria el antígeno para defenderse de él en el futuro.

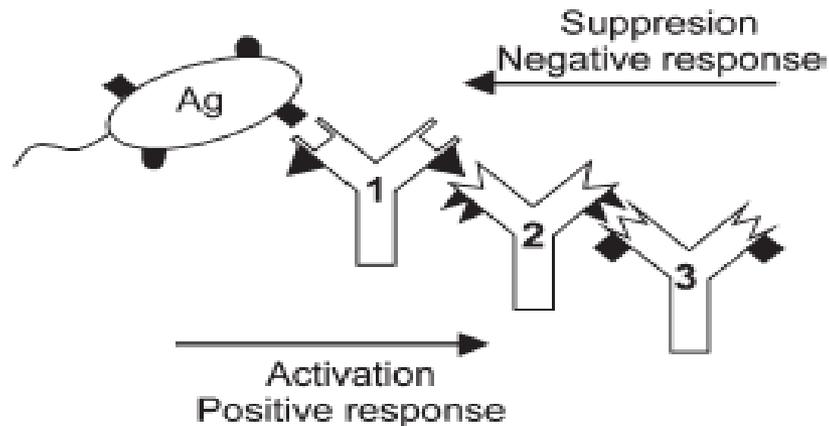
Artificial Inmune Network

Esta teoria fue propuesta por Jerne.

Se hace una hipotesis de que el sistema inmune mantiene una red regular de anticuerpos que mantienen una relacion con los antigenos y con los propios anticuerpos.

Reconocimiento entre anticuerpos obtiene una respuesta negativa y causa una supresion de anticuerpos. Por eso demasiada similitud no es buena y se eliminan del sistema. El sistema se estabiliza cuando los anticuerpos se convierten en cadenas de memoria.

Por eso aunque haya pocos anticuerpos la memoria hace que todos los antigenos sean reconocidos.

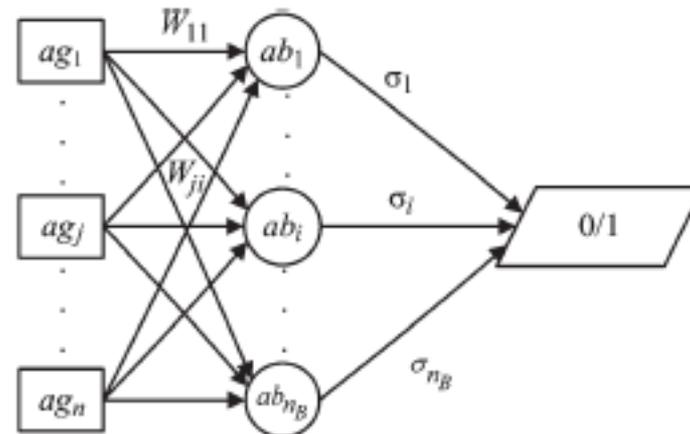
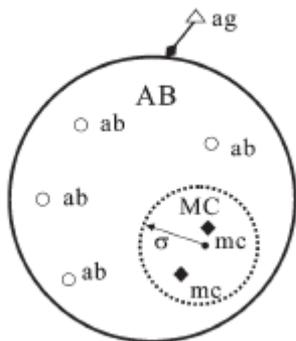


Antibody Population model (AB)

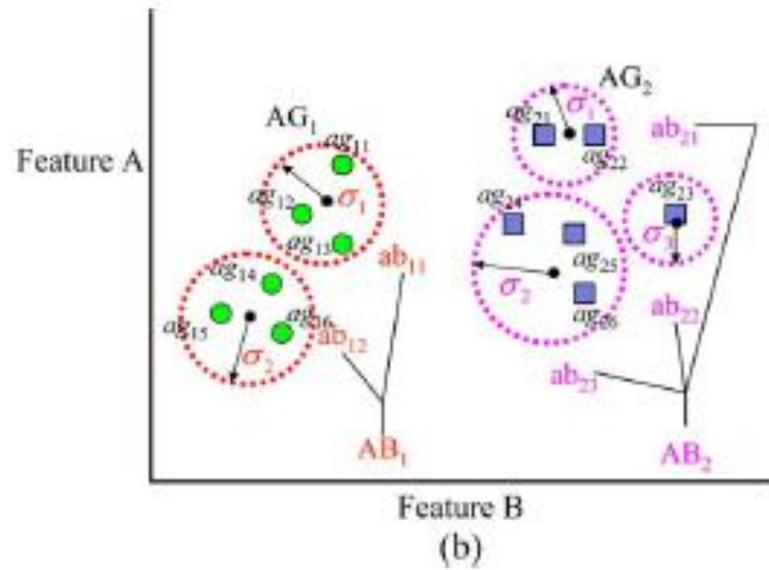
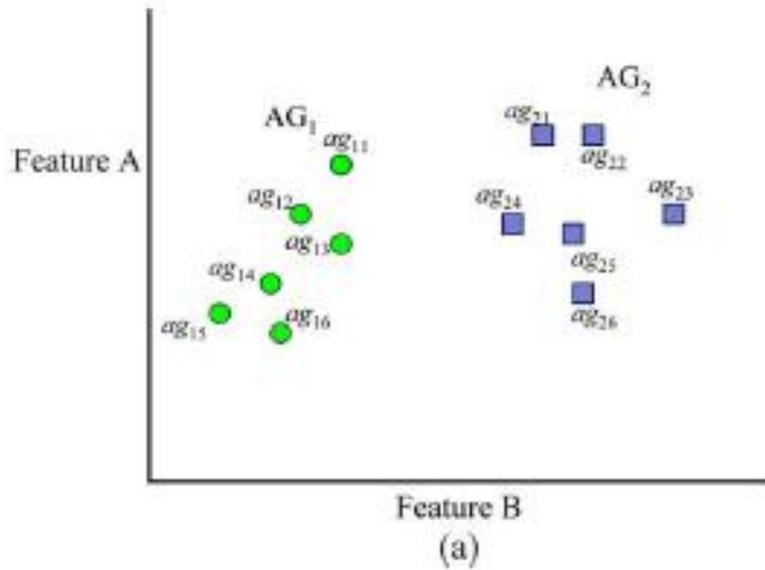
Este modelo describe la población en un sistema inmune que comprende células de memoria (mc) y otros anticuerpos de la misma clase (ab). R_0 representa el radio de influencia, dentro del cual todos los antígenos son reconocidos por el anticuerpo.

Para simplificar el modelo en vez de memoria se va a utilizar el centro del anticuerpo W , y el radio de influencia R_0 .

$$ag.r = f(ag.V, ab.W) = \begin{cases} 1, & WV^T - \sigma > 0 \\ 0, & \text{otherwise} \end{cases}$$



Entrenamiento



Experimentos

- Se han usado tres grupos de imágenes:
 - Landsat TM (Thematic Mapper)
 - Pushbroom Hyperspectral Imager (PHI)
 - Airborne visible/Infrared Imaging Spectrometer (AVIRIS)
- Se han usado 6 algoritmos:
 - MD (minimum distance)
 - GML (Gaussian maximum likelihood)
 - BPNN (back-propagation neural network (ENVI))
 - MVHNC (multiple-valued immune network classifier)
 - RLCRSI (resource-limited classification of remote sensing image)
 - ABNet (artificial antibody network)

Medida del *Accuracy*

- Para validad se ha utilizado además de la comparación entre métodos.
 - Average Accuracy
 - Overall Accuracy
 - Kappa coefficient
- McNemar's test. Copmparacion de clasificadores dos a dos.

$$X^2 = \frac{(|M_{12} - M_{21}| - 1)^2}{M_{12} + M_{21}} \approx \chi_1^2$$

Resultados I

Class	MD	GML	BPNN	MVINC	RLCRSI	ABNet
Yangtze river	99.52%	98.59%	99.19%	99.60%	99.44%	98.22%
Lake	99.51%	96.75%	98.75%	99.17%	98.90%	98.70%
Soil	69.66%	45.31%	81.98%	86.17%	91.25%	87.16%
Vegetation	70.15%	89.83%	87.55%	95.62%	91.89%	94.21%
Building	96.18%	61.67%	63.58%	85.41%	85.64%	87.18%
Bare land/Road	49.48%	91.83%	90.17%	64.92%	71.53%	91.65%
AA	80.75%	80.66%	86.87%	88.48%	89.78%	92.85%
OA	81.89%	84.71%	87.92%	89.87%	90.40%	93.70%
Kappa	0.7796	0.8125	0.8527	0.8761	0.8829	0.9230
Time	3.1s	4.1s	356.3s	5.5s	23.4s	18.6s

Resultados II

Class	MD	GML	BPNN	MVINC	RLCRSI	ABNet
Road	99.86%	99.72%	100%	100%	100%	100%
Corn	77.41%	89.72%	98.32%	99.16%	98.81%	99.23%
Vegetable	65.05%	98.93%	84.85%	86.70%	80.10%	93.59%
Tree	80.61%	55.51%	47.15%	54.75%	70.34%	88.59%
Grass	78.43%	51.76%	38.04%	46.67%	63.92%	71.76%
Water	99.19%	84.76%	99.39%	99.39%	99.80%	100%
Soil	61.37%	68.03%	72.99%	83.93%	86.84%	85.81%
AA	80.27%	78.35%	77.25%	81.51%	85.69%	91.28%
OA	78.62%	86.13%	86.63%	89.50%	90.15%	94.51%
Kappa	0.75	0.835	0.8371	0.8696	0.88	0.9321
Time	3.8s	8.2s	120.3s	6.3s	15.5s	25.4s

Resultados III

Methods (OA)	ABNet (85.41%)	RLCRSI (82.04%)	MVINC (78.24%)	BPNN (75.40%)	GML (73.85%)	MD (42.76%)
ABNet	NA	60.96	225.62	356.66	566.04	3840.47
RLCRSI		NA	115.06	153.66	208.86	3208.26
MVINC			NA	25.722	56.17	2713.13
BPNN				NA	5.888	2500.44
GML					NA	1771.72
MD						NA

$\chi^2_{(0.05,1)} (3.841459).$