



**INSTITUT NATIONAL POLYTECHNIQUE
DE GRENOBLE**

DEA en Sciences Cognitives

**MONOPLAN: Un réseau constructiviste
avec la règle *Minimerror*
Juan Manuel Torres Moreno**

**Jury:
Bernard Amy
Jeanny Hérault
Mirta B. Gordon**

**CEA/Département de Recherche Fondamentale sur la Matière Condensée
Centre d'Etudes Nucléaires de Grenoble
FRANCE 30 Juin, 1994**

PLAN DE LA EXPOSE

- **MOTIVATION**
- **LA REGLE MINIMERROR**
- **L'ALGORITHME MONOPLAN**
- **SIMULATIONS NUMERIQUES**
- **CONCLUSION**

HUMAN FAIL ON XOR PATTERN CLASSIFICATION PROBLEMS

S.J. Thorpe, K.O. Regan et A. Pouget
(Institut des Neurosciences, Univ. Pierre et Marie Curie / Lab. de
Psychologie Expérimentale. Paris 1989)

EXPERIENCE.


Configuration de 4x4 carrés illuminés présentés à une certaine vitesse.

On a mis 3 types des règles:

| | |
|-------------------|--|
| SIMPLE | 1 carré est "ON" |
| ET (AND) | 1 pair de carrés sont "ON" |
| OU EXCLUSIF (XOR) | Si un ou l'autre carré sont "ON" mais non tous deux. |

BUT. Trouver la règle correspondante à la configuration

RESULTATS.



I. MOTIVATION


LA PROBABILITE DE REALISER FONCTIONS BINAIRES COMME FONCTION DU NOMBRE DE COUCHES

Gordon et Peretto, 1990

4 ou 5 couches sont suffisantes pour que la probabilité de réaliser n'importe quelle fonction binaire à 2 entrées, soit équiprobable.

- Dans les systèmes naturels, on pense que l'**ARCHITECTURE COGNITIVE** est déterminée en partie **GENETIQUEMENT** et en partie par l'**APPRENTISSAGE**.
- Dans les systèmes artificiels neuronaux, l'architecture et les efficacités synaptiques devraient être déterminées par un **PROCESSUS D'APPRENTISSAGE** afin d'obtenir un comportement désiré face à un problème posé.

LE PERCEPTRON



N Neurones d'entrée

FONCTIONNEMENT

- Un neurone i qui se trouve dans un état ξ_i agit sur la sortie avec une intensité proportionnelle à son état.
- La somme des influences crée un **CHAMP** à la sortie:

$$h = \sum_{i=1}^N J_i \xi_i$$

- Si le champ dépasse un seuil d'activation $\Theta = -J_0$, la sortie devient active, dans le cas contraire elle est inactive:

$$\sigma = \begin{cases} +1 & \text{si } h > \Theta \\ -1 & \text{si } h < \Theta \end{cases}$$

1. L'ENSEMBLE D'APPRENTISSAGE

Constitué de P couples:

$$\{ \text{exemple, sortie} \} = \{ \xi^\mu, \tau^\mu \}$$

Chaque exemple sera à N entrées.

Le type d'apprentissage à étudier sera:

- **SUPERVISE:** On connaît la réponse que le réseau doit donner aux exemples.
- **BINAIRE:** Etats des neurones d'entrée sont ± 1 .
- **EXHAUSTIF:** Si $P = 2^N$
- **NON-EXHAUSTIF:** Si $P = \alpha N < 2^N$

2. FONCTIONS BOOLEENNES

L'ensemble B de toutes les fonctions booléennes à N entrées contient N_B éléments:

$$N_B = 2^{2^N}$$

Les fonctions booléennes **LINEAIREMENT SEPARABLES (LS)** appartiennent à un sous ensemble réduite de B , avec N_L éléments d'environ:


$$N_L \cong 2 \frac{2^{N^2}}{N!}$$

Par exemple, pour $N = 4$:

- $N_B = 65536$
- $130 < N_L < 170$

Le perceptron peut apprendre seulement des fonctions **LS**

- Le **OU EXCLUSIF (XOR)** n'admet pas une séparation linéaire par un plan quel que soit son orientation.



OU EXCLUSIF

3. LA STABILITE

On définit la **STABILITE** γ^μ d'un exemple μ comme:

$$\gamma^\mu = \tau^\mu \frac{\bar{J}}{\|\bar{J}\|} \cdot \bar{\xi}^\mu$$


avec:

$$\|\bar{J}\| = \sqrt{\sum_{i=0}^N J_i^2} = \text{constante}$$

- La **STABILITE** est la distance de l'exemple μ à l'hyperplan séparateur:

$\gamma^\mu > 0$ si l'exemple est bien appris
 $\gamma^\mu < 0$ autrement.

- Une grande stabilité positive assure une certaine robustesse de la réponse du neurone.



ET (AND)

REGLES D'APPRENTISSAGE TYPE HEBBIAN

Il y a règles d'apprentissage du type Hebbian:

- **LA REGLE DE WIDROW-HOFF**
- **LA REGLE DU PERCEPTRON**

Problèmes:

- **LES ALGORITHMES NE CONVERGENT QUE SI UNE SEPARATION LINEAIRE EST POSSIBLE.**
- **S'IL EXISTE PLUSIEURS SOLUTIONS LA QUALITE DE LA SOLUTION TROUVEE N'EST PAS OPTIMALE.**

PROBLEME

- *Quelle règle d'apprentissage?*
- *Quelle architecture?*
- *Combien d'unités par couche...?*

II. MINIMERROR

1. L'ERREUR MOYENNE

La règle d'apprentissage **MINIMERROR** utilise des considérations de physique statistique pour évaluer l'erreur moyenne.

Elle repose sur deux idées fondamentales:

1. MINIMISER LE NOMBRE DES FAUTES.

2. FAIRE QUE LES STABILITES POSITIVES SOIENT LES PLUS GRANDES POSSIBLES.

MINIMERROR travaille avec la minimisation de la fonction coût:

$$\langle n \rangle = \sum_{\mu=1}^P V(\gamma^{\mu}, \beta)$$

avec:

$$V(\gamma^{\mu}, \beta) = \frac{1}{2} \left(1 - \tanh \frac{\beta \gamma^{\mu}}{2} \right)$$

β est un taux de bruit.

MINIMERROR consiste à minimiser $\langle n \rangle$ à une température finie $T=1/\beta$

2. LE PROBLEME DE LA PARITE A N ENTREES

La généralisation à N entrées du XOR s'appelle la **PARITE: N -PARITE**

$$N\text{-PARITE} = \begin{cases} 1 & \text{Si le nombre de neurones dans} \\ & \text{l'état 1 à l'entrée est pair.} \\ -1 & \text{Autrement.} \end{cases}$$

La N -Parité est une fonction intéressante:


Un perceptron ne peut pas résoudre le problème, mais avec un bon algorithme d'apprentissage on peut réaliser le **NOMBRE MINIMUM DE FAUTES**.

| u | ξ_1 | ξ_2 | ξ_3 | τ |
|-----|---------|---------|---------|--------|
| 1 | -1 | -1 | -1 | 1 |
| 2 | -1 | -1 | 1 | -1 |
| 3 | -1 | 1 | -1 | -1 |
| 4 | -1 | 1 | 1 | 1 |
| 5 | 1 | -1 | -1 | -1 |
| 6 | 1 | -1 | 1 | 1 |
| 7 | 1 | 1 | -1 | 1 |
| 8 | 1 | 1 | 1 | -1 |

La 3-Parité


LE NOMBRE MINIMUM DE FAUTES

Mais, quel est le **NOMBRE MINIMUM DE FAUTES (NMF)** pour la N -Parité?



Le XOR

NMF = 1 Faute



La 3-Parité

NMF = 2 Fautes...

| | k=0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | |
|-----------|------------|----------|----------|----------|----------|----------|----------|----------|----------|----------|-----------|---------------|
| N | - | + | - | + | - | - | + | - | + | - | + | Fautes |
| 2 | 1 | 2 | 1 | | | | | | | | | 1 |
| 3 | 1 | 3 | 3 | 1 | | | | | | | | 2 |
| 4 | 1 | 4 | 6 | 4 | 1 | | | | | | | 5 |
| 5 | 1 | 5 | 10 | 10 | 5 | 1 | | | | | | 10 |
| 6 | 1 | 6 | 15 | 20 | 15 | 6 | 1 | | | | | 22 |
| 7 | 1 | 7 | 21 | 35 | 35 | 21 | 7 | 1 | | | | 44 |
| 8 | 1 | 8 | 28 | 56 | 70 | 56 | 28 | 8 | 1 | | | 93 |
| 9 | 1 | 9 | 36 | 84 | 126 | 126 | 84 | 36 | 9 | 1 | | 186 |
| 10 | 1 | 10 | 45 | 120 | 210 | 252 | 210 | 120 | 45 | 10 | 1 | 386 |

NMF pour la N-Parité

Soit v_k la distribution du nombre des sommets à sortie -1 ou +1 de façon alternée, séparés par des hyperplans successifs.

Le tableau représente le triangle de Pascal.

La distribution des sommets v_k est donnée par les coefficients du binôme:

$$v_k = \binom{N}{k} = \frac{N!}{k! (N-k)!}$$

ANALYSE

- Pour N impair, le **NMF** est égal à deux fois le nombre des fautes commises par un perceptron à $N-1$ entrées.
- Pour N pair, grâce à la symétrie du problème on doit comptabiliser seulement les erreurs commises par les premiers $N/2$ hyperplans.

$$f(N) = \begin{cases} f(N=2p) = \sum_{i=1}^p \binom{2p}{2p+i-1} & p = 1, 2, 3, \dots, N \\ f(N=2p+1) = 2f(2p) \end{cases}$$

SIMULATION NUMERIQUE

Fichier des entrées : **3-PARITE**

Neurones (N) : 3

Patterns (P) : 8

----- NEURONE CACHE 1

Erreur = 2

J: { -0.11 1.16 -1.16 -1.14 }

Fichier des entrées : **5-PARITE**

Neurones (N) : 5

Patterns (P) : 32

----- NEURONE CACHE 1

Erreur = 10

J: { -0.02 -1.01 -1.01 -1.01 -1.01 -1.01 }

III. MONOPLAN


1. LES RESEAUX MULTICOUCHES

- Résoudre des problèmes complexes (non-LS)
- Chaque unité est un perceptron simple
- Unités connectées formant des couches cachées

1. *Quelle est l'architecture la plus performante du réseau?*

- **ARCHITECTURE FIXE**
- **ARCHITECTURE CONSTRUCTIVISTE**

2. *Combien d'unités cachées doit-on mettre dans chaque couche?*



3. ARCHITECTURE FIXE: LA RETRO-PROPAGATION DE L'ERREUR (RP)

- L'apprentissage:
Minimiser l'erreur quadratique commise sur l'ensemble d'apprentissage par une descente en gradient:

Si l'erreur est inférieure a une limite choisie, on arrête l'apprentissage.

- **PROBLEMES DE LA RP...**

1. Le nombre de couches cachées et d'unités par couche sont déterminés *a priori* et modifiés par **essai et erreur!**
2. Des neurones analogiques doivent toujours être utilisés même pour des problèmes qui nécessitaient uniquement des neurones binaires.



4. ARCHITECTURES CONSTRUCTIVISTES

- *THE TILING ALGORITHM* (Mézard et Nadal, 1989)
- *THE UPSTART ALGORITHM* (Freat, 1990)
- *THE OFFSET ALGORITHM* (Martinez et Estève, 1992)
- *MONOPLAN* (Peretto et Gordon, 1992)

5. L'ALGORITHME *MONOPLAN*

COUCHE CACHEE.


- Enseigner au premier neurone l'ensemble d'apprentissage $\{\xi^\mu, \tau^\mu\}$ avec **MINIMERROR**
- Calculer l'état σ_1^μ
- S'il y a des erreurs, on ajoute le deuxième neurone mais pour lui, on enseigne la projection du neurone avant $\sigma_1^\mu \tau^\mu$
- Ajouter neurones tandis qu'il y a des erreurs, avec la projection $\sigma_{NH-1}^\mu \tau_{NH-1}^\mu$ pour l'unité NH .



SORTIE.

- Enseigner l'ensemble {Représentations Internes, sortie} $\{\sigma^\mu, \tau^\mu\}$ avec **MINIMERROR**
- Calculer son état σ
- S'il n'y a plus des fautes la procédure termine, sinon ajouter l'unité $NH+1$
- Itérer avec la projection $\sigma \tau^\mu$ jusqu'à la convergence.

ENTREES \rightarrow **REP. INTERNES** \rightarrow **SORTIE**



MONOPLAN construit un réseau simple: à une couche cachée

IV. SIMULATIONS

1. APPRENTISSAGE EXHAUSTIF DE LA N -PARITE

Tests de la N -Parité ($N \leq 10$).

On a trouvé toujours la solution optimale avec $NH=N$ unités cachées.

| i | Couche cachée | | | | | | | | | | |
|----|---------------|-------|--|-------|-------|-------|-------|-------|-------|-------|-------|
| | Biais | | Synapses (couche d'entrée à l'unité i) | | | | | | | | |
| 1 | -1.04 | -1.10 | 0.52 | 1.00 | 1.03 | -1.03 | -1.07 | -1.02 | -1.00 | -1.07 | -1.00 |
| 2 | 1.44 | -0.93 | 0.88 | 0.92 | 0.92 | -0.96 | -0.93 | -0.97 | -1.06 | -0.93 | -0.93 |
| 3 | 2.45 | 0.68 | -0.69 | -0.73 | -0.71 | 0.68 | 0.72 | 0.74 | 0.73 | 0.71 | 0.68 |
| 4 | 2.47 | -0.70 | 0.72 | 0.69 | 0.70 | -0.70 | -0.71 | -0.69 | -0.71 | -0.68 | -0.69 |
| 5 | 2.87 | -0.54 | 0.54 | 0.51 | 0.53 | -0.52 | -0.52 | -0.54 | -0.50 | -0.54 | -0.52 |
| 6 | 2.84 | 0.49 | -0.50 | -0.58 | -0.53 | 0.54 | 0.54 | 0.57 | 0.56 | 0.54 | 0.55 |
| 7 | 3.03 | 0.39 | -0.37 | -0.46 | -0.45 | 0.41 | 0.42 | 0.43 | 0.47 | 0.42 | 0.45 |
| 8 | 3.06 | -0.45 | 0.46 | 0.33 | 0.39 | -0.42 | -0.43 | -0.40 | -0.37 | -0.43 | -0.39 |
| 9 | 3.12 | 0.23 | -0.17 | -0.62 | -0.40 | 0.26 | 0.19 | 0.31 | 0.49 | 0.25 | 0.39 |
| 10 | 3.12 | -0.49 | 0.63 | 0.17 | 0.22 | -0.28 | -0.42 | -0.33 | -0.22 | -0.38 | -0.15 |

| | Unité de sortie | | | | | | | | | | |
|--|-----------------|------|-------|--------------------------------------|------|-------|-------|------|------|-------|-------|
| | Biais | | | Synapses (couche cachée à la sortie) | | | | | | | |
| | 1.00 | 1.00 | -1.00 | 1.00 | 1.00 | -1.00 | -1.00 | 1.00 | 1.00 | -1.00 | -1.00 |

La 10-Parité

DEGENERESCENCE DES RI

- A chaque exemple de l'entrée on associe une **RI**.
- Plusieurs exemples peuvent être associés à la même **RI**.

On aura pour P exemples, P^* **RI** différentes. $P^* < P$.

On doit travailler avec toutes ou sans les **RI** répétés?...

**DEUX REPRESENTATIONS INTERNES IDENTIQUES
SONT INCAPABLES DE PRODUIRE DEUX SORTIES DIFFERENTES**

Donc, on a décidé:

- Eliminer les RI répétés \Rightarrow
Trouver la sortie la plus stable possible.

AVEC OU SANS TOUTES LES REPRESENTATIONS INTERNES?

Solution pour la 6-Parité avec toutes les *RI*.

| Couche cachée | | | | | | | |
|---------------|--|-------|-------|-------|-------|-------|-------|
| i | Biais Synapses (couche d'entrée à l'unité i) | | | | | | |
| 1 | 1.00 | -1.00 | 1.00 | -1.00 | -1.00 | 1.00 | -1.00 |
| 2 | 1.42 | 0.91 | -0.91 | 0.91 | 0.91 | -0.91 | 0.91 |
| 3 | 2.17 | -0.62 | 0.62 | -0.62 | -0.62 | 0.62 | -0.62 |
| 4 | 2.17 | 0.62 | -0.62 | 0.62 | 0.62 | -0.62 | 0.62 |
| 5 | 2.38 | 0.47 | 0.47 | -0.47 | -0.47 | 0.47 | -0.47 |
| 6 | 2.38 | 0.47 | -0.47 | 0.47 | 0.47 | -0.47 | 0.47 |

| Unité de sortie | | | | | | |
|-----------------|--------------------------------------|-------------|--------------|--------------|-------------|-------------|
| Biais | Synapses (couche cachée à la sortie) | | | | | |
| -0.73 | 1.16 | 1.16 | -1.07 | -1.07 | 0.86 | 0.86 |


Solution sans *RI* répétés (la couche cachée a les mêmes poids).

| Unité de sortie | | | | | | |
|-----------------|--------------------------------------|-------------|--------------|--------------|-------------|-------------|
| Biais | Synapses (couche cachée à la sortie) | | | | | |
| -1.00 | 1.00 | 1.00 | -1.00 | -1.00 | 1.00 | 1.00 |

LA STABILITE DANS LE MEME ESPACE DES ENTREES

Pour un problème à 2 entrées, la **STABILITE** γ^μ mesure la distance du plan P à l'exemple μ dans un espace **TRIDIMENSIONNEL**.


La distance efficace qu'on *voudrait maximiser* est la **DISTANCE** d^μ (de la droite D) mesuré sur un espace **BIDIMENSIONNEL**.



γ^μ vs. d^μ

$$d^\mu = \frac{\gamma^\mu}{\sqrt{1 - \frac{J_0^2}{\|\vec{J}\|^2}}}$$

Résultats de la N -Parité ($N \leq 6$) à la sortie.



γ^μ vs d^μ

2. APPRENTISSAGE NON EXHAUSTIF DE LA N -PARITE: LA GENERALISATION


Si l'ensemble d'apprentissage a moins de 2^N exemples (NON-EXHAUSTIF), on peut se poser la question:

Quelle est la performance du réseau face à des exemples qui n'a vu jamais?...

La généralisation de la N -Parité ($N \leq 7$).

Pourcentage de réponses erronées par rapport à $\alpha = P/N$

Généralisation pour la N -Parité



V. CONCLUSION

1. L'architecture final est simple: une seule couche cachée
2. Les tests sur la N -Parité sont très satisfaisants: on trouve la solution de réseau minimal de plus grande stabilité et NMF.

La minimisation avec d^μ rendre plus grandes les stabilités qu'avec γ^μ dans le N -Parité. Mais de plus en plus $d^\mu \rightarrow \gamma^\mu$. A la limite quand $N \rightarrow \infty$, $d^\mu \equiv \gamma^\mu$.

PERSPECTIVES

1. Tests sur l'altération aléatoire des sorties:
 - i). Apprendre une fonction f LS à N entrées.
 - ii). Pour $k=1, \dots, N$
 - $f' \leftarrow f$ avec k bits changés
 - Essayer d'apprendre f' avec NH unitésVérifier que $NH \leq k+1$.
2. Utilisation de momentum α , pour la descente en gradient.
3. Tests sur l'altération des synapses.
4. Paralléliser les algorithmes.

*Si l'Homme est "Neuronal", le Neurone,
lui, est très certainement inhumain.*