

*Apprentissage à partir de données  
diversement étiquetées pour l'étude du rôle  
de l'environnement local dans les  
interactions entre acides aminés*

**Christophe N. Magnan**

*Université de Provence - Aix-Marseille I*

*Laboratoire d'Informatique Fondamentale, UMR CNRS 6166  
Ecole Doctorale Mathématiques et Informatique de Marseille (ED 184)*

**Sous la direction de François Denis (PR, LIF) et Cécile Capponi (MCF, LIF)**



*12 Décembre 2007*

*Apprentissage pour  
l'étude des  
interactions entre  
acides aminés*

*Christophe Magnan*

*Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

*Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

*Information Locale*

*1ère approche*

*Modèle proposé*

*Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

*Expérimentation du  
protocole*

*Conclusion*

*Conclusions*

*Perspectives*

## Cadre de cette étude

- Modélisation *de novo* de la structure 3D des protéines
- Apprentissage automatique

### Introduction

Protéines et structure

Modélisation *de novo*

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Cadre de cette étude

- Modélisation *de novo* de la structure 3D des protéines
- Apprentissage automatique

## A.C.I. Masses de données *Genoto3D*

- **Responsable** : Yann Guermeur (LORIA)
- **Laboratoires** : LORIA, IBCP, IRISA, LIRMM, INRA, LIF
- **Dates** : Avril 2003 - Novembre 2006
- **Cadre** : prédiction de la structure 3D des protéines

### Introduction

Protéines et structure

Modélisation *de novo*

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

Ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

# Protéines, fonctions, et conformation spatiale

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

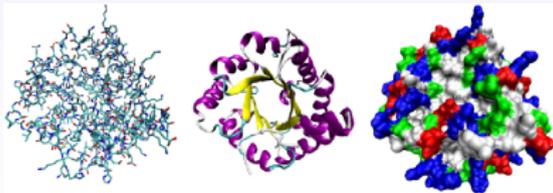
Christophe Magnan

## Les protéines

- Chaînes d'acides aminés (20 acides aminés)
- Responsables de la totalité des activités cellulaires
- Fonctions physiologiques en grande partie conférées par la structure 3D  $\Rightarrow$  **nécessité de connaître la conformation spatiale**

## Exemple de séquence primaire (Id. PDB 1TIM)

APRKFVFGNWNKMNGKRKSLGELIHTLDGAKLSADTEVVCGAPSIYLDFAHQKLDKAGVAAQNCYKVPKGAFTGEISPAMI  
KDIGAAWVILGHSERRHVFGEDELIGQKVAHALAELGLVIACIGEKLDEREAGITEKVVVFQETKAIADNVKDWKVVLAYEPV  
WAIGTGKTATPQQAQEVHEKLRGWLKTHVSDAVAVQSRRIYGGSVTGGNCKELASQHDVDGFLVGGASLKPEFVDIINAKH



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Séquences protéiques (Swiss-Prot, TrEMBL)

- Extraites des séquençages automatiques de génomes
- $\simeq$  5 Millions de séquences recensées

## Structures 3D (Protein Data Bank)

- Déterminées par R.M.N., Radiocristallographie, ...
- $\simeq$  47000 structures déterminées  
⇒ nécessité de proposer d'autres techniques de modélisation

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Principe

- Prédiction de la structure à partir de la séquence
- Méthodes issues de l'apprentissage automatique
- Appuyées par les travaux d'Anfinsen (Prix Nobel, 1972)

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Principe

- Prédiction de la structure à partir de la séquence
- Méthodes issues de l'apprentissage automatique
- Appuyées par les travaux d'Anfinsen (Prix Nobel, 1972)

## Prédiction de la structure secondaire

- Formes caractéristiques fréquentes : hélices  $\alpha$ , brins  $\beta$ , angles
- Méthodes performantes [Ruan et al., 2005, Cheng et Baldi, 2007]



## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

1ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions

Perspectives

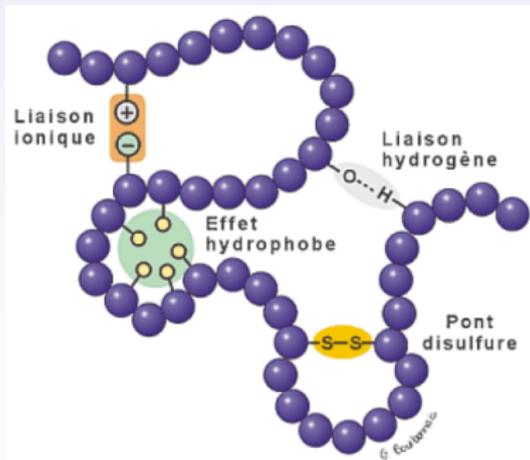
# Contacts entre deux acides aminés distants

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Différents types de contacts

- Ponts disulfures (liaisons covalentes entre deux cystéines)
- Ponts salins (liaisons ioniques)
- Liaisons hydrogène
- ...



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

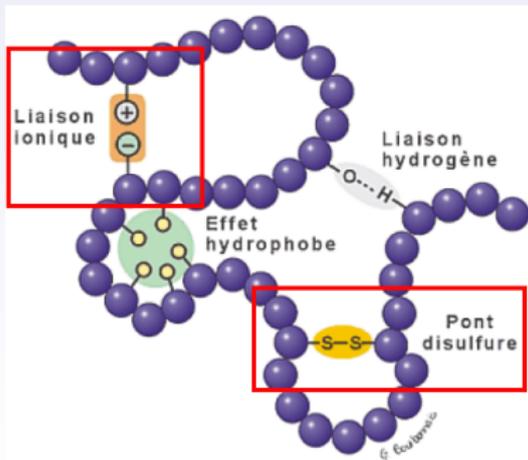
# Contacts entre deux acides aminés distants

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Différents types de contacts

- **Ponts disulfures** (liaisons covalentes entre deux cystéines)
- **Ponts salins** (liaisons ioniques)
- Liaisons hydrogène
- ...



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

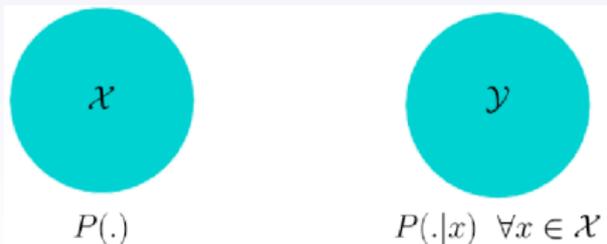
# Classification supervisée

## Description

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $P$  sur  $\mathcal{X} \times \mathcal{Y}$ , supposée fixe mais inconnue
- $\mathcal{X}$  : espace de description,  $\mathcal{Y}$  : classes ( $= \{+, -\}$ )

## Prédiction des ponts disulfures

- $\mathcal{X}$  = descriptions d'une paire de cystéines oxydées
- $\mathcal{Y}$  = appariée / non appariée



## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

Ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions

Perspectives

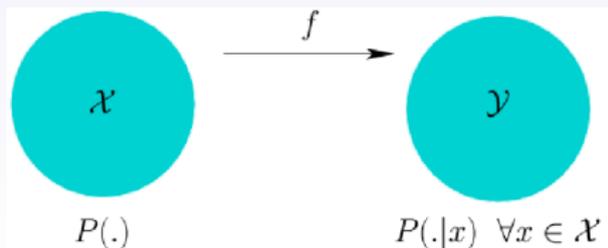
# Classification supervisée

## Description

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $P$  sur  $\mathcal{X} \times \mathcal{Y}$ , supposée fixe mais inconnue
- $\mathcal{X}$  : espace de description,  $\mathcal{Y}$  : classes ( $= \{+, -\}$ )

## Objectif

- Calculer, à partir de  $S$ , un classifieur  $f : \mathcal{X} \rightarrow \mathcal{Y}$
- Critère : minimiser  $R(f) = P(f(x) \neq y)$



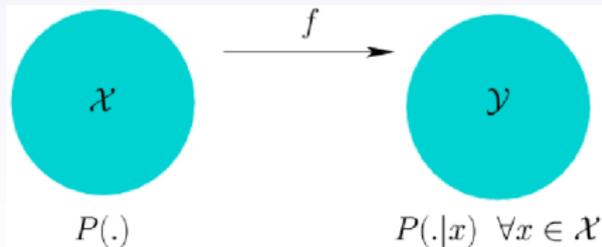
# Classification supervisée

## Description

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $P$  sur  $\mathcal{X} \times \mathcal{Y}$ , supposée fixe mais inconnue
- $\mathcal{X}$  : espace de description,  $\mathcal{Y}$  : classes ( $= \{+, -\}$ )

## Solution optimale : la règle de Bayes

- $\forall x \in \mathcal{X}, f_{\text{Bayes}}(x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y|x)$
- $P$  inconnue et  $S$  ne permet généralement pas de l'approximer



## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

Ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions

Perspectives

# « Variantes » de la classification supervisée

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Classification semi-supervisée

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $S_{unl} = \{x'_1, \dots, x'_l\}$  i.i.d. selon  $P(\cdot)$  sur  $\mathcal{X}$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# « Variantes » de la classification supervisée

## Classification semi-supervisée

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $S_{unl} = \{x'_1, \dots, x'_l\}$  i.i.d. selon  $P(\cdot)$  sur  $\mathcal{X}$

## Classification supervisée avec présence de bruit de classification

- $S^\eta = \{(x_1, y_1^\eta), \dots, (x_l, y_l^\eta)\}$
- Les classes originales  $y_i$  sont corrompues avant d'être observées
- Différents modèles de bruit de classification
- **Ex** : bruit de classification uniforme CN [Angluin et Laird, 1988]  
 $y_i^\eta \neq y_i$  avec probabilité  $\eta < 0.5$  constante ( $\mathcal{Y} = \{+, -\}$ )

# « Variantes » de la classification supervisée

## Classification semi-supervisée

- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  i.i.d. selon  $P(x, y) = P(x) \cdot P(y|x)$
- $S_{unl} = \{x'_1, \dots, x'_l\}$  i.i.d. selon  $P(\cdot)$  sur  $\mathcal{X}$

## Classification supervisée avec présence de bruit de classification

- $S^\eta = \{(x_1, y_1^\eta), \dots, (x_l, y_l^\eta)\}$
- Les classes originales  $y_i$  sont corrompues avant d'être observées
- Différents modèles de bruit de classification
- **Ex** : bruit de classification uniforme CN [Angluin et Laird, 1988]  
 $y_i^\eta \neq y_i$  avec probabilité  $\eta < 0.5$  constante ( $\mathcal{Y} = \{+, -\}$ )

## Objectif

Identique au cas supervisé classique

# *I*

*Première étude du problème de  
la prédiction des ponts disulfures  
et  
contribution à l'apprentissage  
semi-supervisé asymétrique*

*Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

*Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

*Information Locale*

*ère approche*

*Modèle proposé*

*Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

*Expérimentation du  
protocole*

*Conclusion*

*Conclusions*

*Perspectives*

# Prédiction des ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

Deux étapes de prédiction :

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

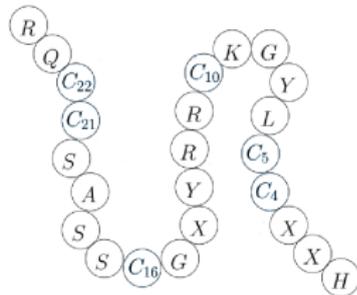
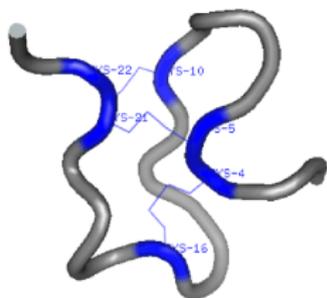
Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

1AS5 H X X C<sub>4</sub> C<sub>5</sub> L Y G K C<sub>10</sub> R R Y X G C<sub>16</sub> S S A S C<sub>21</sub> C<sub>22</sub> Q R



# Prédiction des ponts disulfures

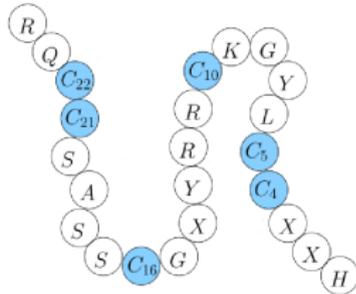
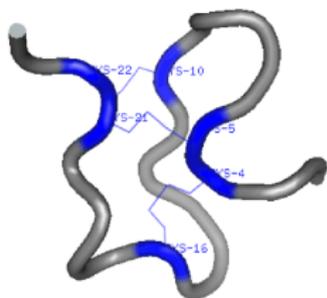
Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Deux étapes de prédiction :

- Quelles cystéines forment un pont ?  $\Rightarrow$  traitée efficacement

1AS5 H X X C<sub>4</sub> C<sub>5</sub> L Y G K C<sub>10</sub> R R Y X G C<sub>16</sub> S S A S C<sub>21</sub> C<sub>22</sub> Q R



## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

Ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions

Perspectives

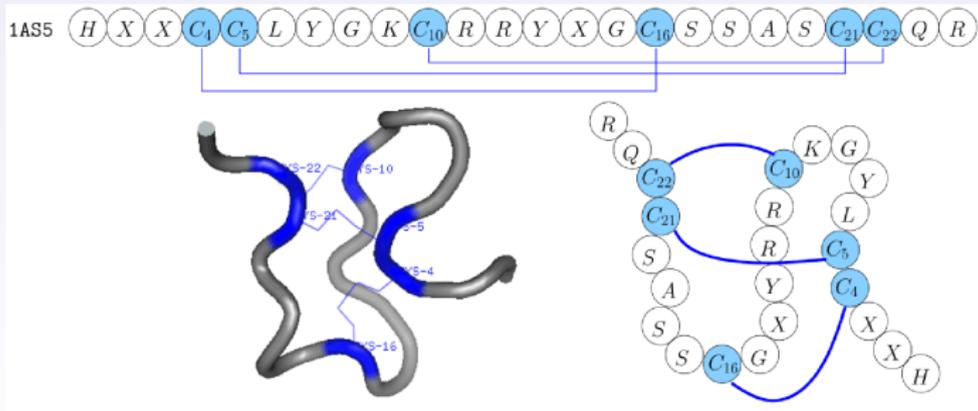
# Prédiction des ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Deux étapes de prédiction :

- Quelles cystéines forment un pont ?  $\Rightarrow$  **traitée efficacement**
- Les ponts eux-mêmes (appariements)  $\Rightarrow$  **problème ouvert**



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Prédiction des ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Travaux de référence sur le problème

- [Fariselli et al., 2001, 2002, Vullo et Frasconi, 2003, 2004] ...
- De fortes similarités dans tous ces travaux

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ière approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

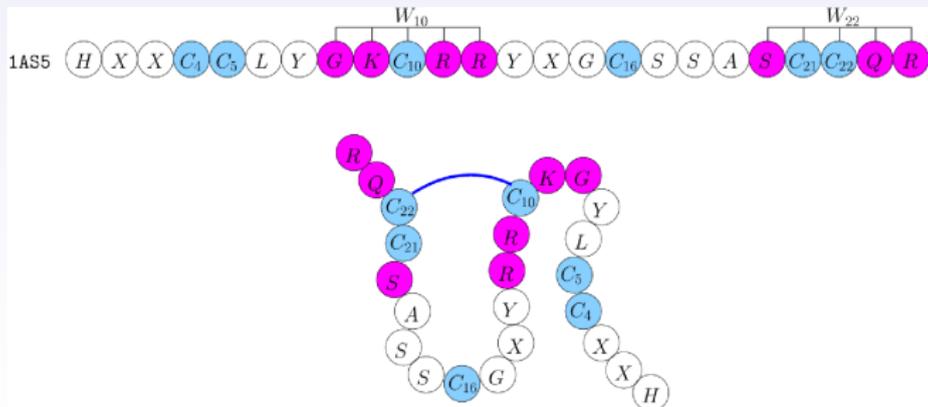
# Prédiction des ponts disulfures

## Travaux de référence sur le problème

- [Fariselli et al., 2001, 2002, Vullo et Frasconi, 2003, 2004] ...
- De fortes similarités dans tous ces travaux

## Le choix de la description des paires de cystéines oxydées

- Principalement : l'environnement local des cystéines sur la séquence
- Une paire  $(C_i, C_j)$  décrite par  $(W_i, W_j)$
- $(W_i, W_j)$  codées sous forme vectorielle



## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

1ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions

Perspectives

# Prédiction des ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

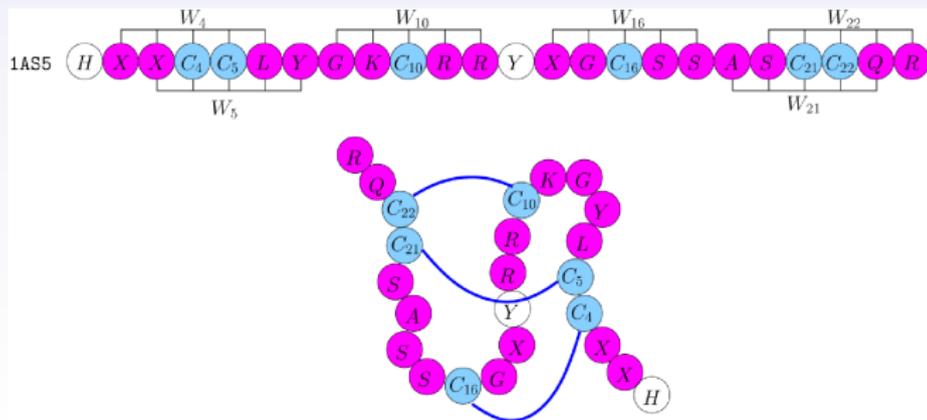
Christophe Magnan

## Travaux de référence sur le problème

- [Fariselli et al., 2001, 2002, Vullo et Frasconi, 2003, 2004] ...
- De fortes similarités dans tous ces travaux

## Notre première étude

- Pourquoi ce choix ? caractériser les paires « compatibles » des autres
- Aucune preuve biologique, certains biologistes sceptiques
- **Quelle implication sur le statut des paires non appariées ?**



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Notion d'affinité entre contextes locaux

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Statut des paires observées

- **Les paires appariées** : des exemples positifs de paires compatibles
- **Les paires non appariées ?**
  - Contraintes d'unicité d'appariement et globales sur la structure
  - Des exemples négatifs de paires compatibles ?

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Notion d'affinité entre contextes locaux

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Statut des paires observées

- **Les paires appariées** : des exemples positifs de paires compatibles
- **Les paires non appariées ?**
  - Contraintes d'unicité d'appariement et globales sur la structure
  - Des exemples négatifs de paires compatibles ?

## Notre hypothèse

- **Paires non appariées** : exemples de classe non déterminée
- **Données observées** : positives et non étiquetées
- Apprentissage **semi-supervisé asymétrique** [Denis, 1998]

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Notion d'affinité entre contextes locaux

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Statut des paires observées

- **Les paires appariées** : des exemples positifs de paires compatibles
- **Les paires non appariées ?**
  - Contraintes d'unicité d'appariement et globales sur la structure
  - Des exemples négatifs de paires compatibles ?

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Notre hypothèse

- **Paires non appariées** : exemples de classe non déterminée
- **Données observées** : positives et non étiquetées
- Apprentissage **semi-supervisé asymétrique** [Denis, 1998]

## Idée

- Comparer les performances de classifieurs appris à partir :
  - de la modélisation supervisée
  - de la modélisation semi-supervisée asymétrique
- peu de résultats exploitables en contexte semi-supervisé asymétrique  
⇒ **nécessite une étude de ce contexte**

# Apprentissage semi-supervisé asymétrique

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Cadre général de l'apprentissage statistique

- La distribution  $P$  sur  $\mathcal{X} \times \mathcal{Y}$  est déterminée par :
  - $P(\cdot)$  sur  $\mathcal{X}$
  - $P(\cdot|y = +)$  sur  $\mathcal{X}$  (notée  $P(\cdot|+)$ )
  - $P(y = +)$  (notée  $P(+)$ )

## Apprentissage semi-supervisé asymétrique

- Suppose que l'on dispose :
  - d'exemples positifs, tirés selon  $P(\cdot|+)$  sur  $\mathcal{X}$
  - d'exemples non étiquetés, tirés selon  $P(\cdot)$  sur  $\mathcal{X}$
- si  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P(+)$  alors  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P$  sur  $\mathcal{X} \times \mathcal{Y}$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Apprentissage semi-supervisé asymétrique

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Cadre général de l'apprentissage statistique

- La distribution  $P$  sur  $\mathcal{X} \times \mathcal{Y}$  est déterminée par :
  - $P(\cdot)$  sur  $\mathcal{X}$
  - $P(\cdot|y = +)$  sur  $\mathcal{X}$  (notée  $P(\cdot|+)$ )
  - $P(y = +)$  (notée  $P(+)$ )

## Apprentissage semi-supervisé asymétrique

- Suppose que l'on dispose :
  - d'exemples positifs, tirés selon  $P(\cdot|+)$  sur  $\mathcal{X}$
  - d'exemples non étiquetés, tirés selon  $P(\cdot)$  sur  $\mathcal{X}$
- si  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P(+)$  alors  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P$  sur  $\mathcal{X} \times \mathcal{Y}$

## Proposition

Sans information supplémentaire,  $P(+)$  n'est pas déterminée par  $P(\cdot)$  sur  $\mathcal{X}$  et  $P(\cdot|+)$  sur  $\mathcal{X}$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Apprentissage semi-supervisé asymétrique

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Cadre général de l'apprentissage statistique

- La distribution  $P$  sur  $\mathcal{X} \times \mathcal{Y}$  est déterminée par :
  - $P(\cdot)$  sur  $\mathcal{X}$
  - $P(\cdot|y = +)$  sur  $\mathcal{X}$  (notée  $P(\cdot|+)$ )
  - $P(y = +)$  (notée  $P(+)$ )

## Apprentissage semi-supervisé asymétrique

- Suppose que l'on dispose :
  - d'exemples positifs, tirés selon  $P(\cdot|+)$  sur  $\mathcal{X}$
  - d'exemples non étiquetés, tirés selon  $P(\cdot)$  sur  $\mathcal{X}$
- si  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P(+)$  alors  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P$  sur  $\mathcal{X} \times \mathcal{Y}$

## Proposition

Sans information supplémentaire,  $P(+)$  n'est pas déterminée par  $P(\cdot)$  sur  $\mathcal{X}$  et  $P(\cdot|+)$  sur  $\mathcal{X}$  : c'est un problème mal posé

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Hypothèses rendant le problème bien posé

*Problèmes déterministes* :  $\forall x \in \mathcal{X}, P(+|x) = 1$  ou  $P(+|x) = 0$

$$P(+) = \sum_{x \in \mathcal{X} / P(x|+) \neq 0} P(x)$$

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Hypothèses rendant le problème bien posé

*Problèmes déterministes* :  $\forall x \in \mathcal{X}, P(+|x) = 1$  ou  $P(+|x) = 0$

$$P(+) = \sum_{x \in \mathcal{X} / P(x|+) \neq 0} P(x)$$

*Hypothèse « naïve » de Bayes* :  $P(\cdot|y)$  distributions produits

- $P(x|y) = \prod_{i=1}^m P(x^i|y) \quad \forall x = (x^1, \dots, x^m) \in \mathcal{X} = \prod_{i=1}^m \mathcal{X}^i$

# Hypothèses rendant le problème bien posé

*Problèmes déterministes* :  $\forall x \in \mathcal{X}, P(+|x) = 1$  ou  $P(+|x) = 0$

$$P(+) = \sum_{x \in \mathcal{X} / P(x|+) \neq 0} P(x)$$

*Hypothèse « naïve » de Bayes* :  $P(\cdot|y)$  distributions produits

- $P(x|y) = \prod_{i=1}^m P(x^i|y) \quad \forall x = (x^1, \dots, x^m) \in \mathcal{X} = \prod_{i=1}^m \mathcal{X}^i$
- $P(\cdot) = \alpha P(\cdot|+) + (1 - \alpha)P(\cdot|-)$  avec  $\alpha = P(+)$ , **or les mélanges finis de distributions produits sont identifiables** [Yakowitz et Spragins, 1968]

# Hypothèses rendant le problème bien posé

*Problèmes déterministes* :  $\forall x \in \mathcal{X}, P(+|x) = 1$  ou  $P(+|x) = 0$

$$P(+) = \sum_{x \in \mathcal{X} / P(x|+) \neq 0} P(x)$$

*Hypothèse « naïve » de Bayes* :  $P(\cdot|y)$  distributions produits

- $P(x|y) = \prod_{i=1}^m P(x^i|y) \quad \forall x = (x^1, \dots, x^m) \in \mathcal{X} = \prod_{i=1}^m \mathcal{X}^i$
- $P(\cdot) = \alpha P(\cdot|+) + (1 - \alpha)P(\cdot|-)$  avec  $\alpha = P(+)$ , **or les mélanges finis de distributions produits sont identifiables** [Yakowitz et Spragins, 1968]
- Nous montrons que  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P(+)$ 
  - sous des conditions plus faibles
  - prise en compte de la distribution  $P(\cdot|+)$  sur  $\mathcal{X}$

# Hypothèses rendant le problème bien posé

**Problèmes déterministes** :  $\forall x \in \mathcal{X}, P(+|x) = 1$  ou  $P(+|x) = 0$

$$P(+)=\sum_{x \in \mathcal{X} / P(x|+) \neq 0} P(x)$$

**Hypothèse « naïve » de Bayes** :  $P(\cdot|y)$  distributions produits

- $P(x|y) = \prod_{i=1}^m P(x^i|y) \forall x = (x^1, \dots, x^m) \in \mathcal{X} = \prod_{i=1}^m \mathcal{X}^i$
- $P(\cdot) = \alpha P(\cdot|+) + (1 - \alpha)P(\cdot|-)$  avec  $\alpha = P(+)$ , **or les mélanges finis de distributions produits sont identifiables** [Yakowitz et Spragins, 1968]
- Nous montrons que  $P(\cdot|+)$  et  $P(\cdot) \Rightarrow P(+)$ 
  - sous des conditions plus faibles
  - prise en compte de la distribution  $P(\cdot|+)$  sur  $\mathcal{X}$

$$P(+)=\frac{P(x^i=k, x^j=l) - P(x^i=k)P(x^j=l)}{P(x^i=k|+)P(x^j=l|+) - P(x^i=k)P(x^j=l|+) - P(x^j=l)P(x^i=k|+) + P(x^i=k, x^j=l)}$$

## Hypothèse naïve de Bayes et classifieur de Bayes

- Le classifieur de Bayes devient le classifieur naïf de Bayes :

$$f_{NB}(x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y|x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y) \cdot \prod_{i=1}^m P(x^i|y)$$

- Classifieur simple mais efficace [Domingos et Pazzani, 1996]

## Hypothèse naïve de Bayes et classifieur de Bayes

- Le classifieur de Bayes devient le classifieur naïf de Bayes :

$$f_{NB}(x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y|x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y) \cdot \prod_{i=1}^m P(x^i|y)$$

- Classifieur simple mais efficace [Domingos et Pazzani, 1996]

## Classifieur Naïf de Bayes

- Spécifié par les paramètres :
  - $P(+)$
  - $p_{ik} = P(x^i = k|+)$
  - $q_{ik} = P(x^i = k|-)$
- $\theta = \{P(+), p_{ik}, q_{ik}\}$  est appelé *modèle naïf de Bayes*

## Hypothèse naïve de Bayes et classifieur de Bayes

- Le classifieur de Bayes devient le classifieur naïf de Bayes :

$$f_{NB}(x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y|x) = \underset{y \in \mathcal{Y}}{\operatorname{argmax}} P(y) \cdot \prod_{i=1}^m P(x^i|y)$$

- Classifieur simple mais efficace [Domingos et Pazzani, 1996]

## Classifieur Naïf de Bayes

- Spécifié par les paramètres :
  - $P(+)$
  - $p_{ik} = P(x^i = k|+)$
  - $q_{ik} = P(x^i = k|-)$
- $\theta = \{P(+), p_{ik}, q_{ik}\}$  est appelé *modèle naïf de Bayes*
- Tous les paramètres de ces modèles sont déterminés en contexte semi-supervisé asymétrique

## NB-SSA : adaptation semi-supervisée asymétrique de NB

- Entrée :  $S_{pos}, S_{unl}$
- Sortie :  $\hat{\theta} = \{ \hat{P}(+), \hat{p}_{ik}, \hat{q}_{ik} \}$
- $S_{pos} \rightarrow \hat{p}_{ik}$        $\hat{p}_{ik}$  et  $S_{unl} \rightarrow \hat{P}(+)$        $\hat{p}_{ik}, S_{unl}$  et  $\hat{P}(+) \rightarrow \hat{q}_{ik}$

[Magnan, CAp 2005, RIA 2006]

$$\hat{P}(+) = \frac{\sum_{\substack{i,j \in \{1, \dots, m\}, i \neq j \\ k \in \mathcal{X}^i, l \in \mathcal{X}^j}} \hat{P}(x^i=k, x^j=l) - \hat{P}(x^i=k) \hat{P}(x^j=l)}{\sum_{\substack{i,j \in \{1, \dots, m\}, i \neq j \\ k \in \mathcal{X}^i, l \in \mathcal{X}^j}} \hat{p}_{ik} \hat{p}_{jl} - \hat{P}(x^i=k) \hat{p}_{jl} - \hat{P}(x^j=l) \hat{p}_{ik} + \hat{P}(x^i=k, x^j=l)}$$

$$\hat{q}_{ik} = \frac{\hat{P}(x^i = k) - \hat{p}_{ik} \hat{P}(+)}{1 - \hat{P}(+)}$$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Maximisation de la Vraisemblance

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

*NB-SSA-EM : NB-SSA + Méthode E.M. [Dempster et al., 1977]*

- Vraisemblance :  $L(\theta, S) = \prod_{z_i \in S} P(z_i | \theta)$
- EM : méthode itérative pour obtenir un maximum local de  $L(\theta, S)$
- **Modèle initial**  $\theta_0$  : calculé avec NB-SSA
- **Modèles**  $\theta_{n+1}$  ( $n \geq 0$ ) : obtenus à partir de  $\theta_n$ ,  $S_{pos}$  et  $S_{unl}$

[Magnan, CAP 2005, RIA 2006]

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Maximisation de la Vraisemblance

**NB-SSA-EM** : NB-SSA + Méthode E.M. [Dempster et al., 1977]

- Vraisemblance :  $L(\theta, S) = \prod_{z_i \in S} P(z_i | \theta)$
- EM : méthode itérative pour obtenir un maximum local de  $L(\theta, S)$
- **Modèle initial**  $\theta_0$  : calculé avec NB-SSA
- **Modèles**  $\theta_{n+1}$  ( $n \geq 0$ ) : obtenus à partir de  $\theta_n$ ,  $S_{pos}$  et  $S_{unl}$

[Magnan, CAP 2005, RIA 2006]

$$P(+) = \frac{l + \sum_{i=1}^{l'} \hat{P}(y'_i = + | x'_i, \theta_n)}{l + l'}$$

$$p_{jk} = \frac{n_{jk} + \sum_{x'_i \in S_{unl} / x'_i{}^j = k} \hat{P}(y'_i = + | x'_i, \theta_n)}{l + \sum_{i=1}^{l'} \hat{P}(y'_i = + | x'_i, \theta_n)} \quad q_{jk} = \frac{\sum_{x'_i \in S_{unl} / x'_i{}^j = k} \hat{P}(y'_i = - | x'_i, \theta_n)}{\sum_{i=1}^{l'} \hat{P}(y'_i = - | x'_i, \theta_n)}$$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Expériences sur données ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Description

- Protocole identique à celui des travaux du domaine
- Jeu de données préparé par C. Geourjon (IBCP, Lyon)
- Nombreuses séries (rayon des fenêtres, codage)
- Comparaison avec un choix aléatoire des ponts

Description du jeu de données	
Nb de ponts	Nb de protéines
2	77
3	64
4	33
5	24

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Expériences sur données ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Description

- Protocole identique à celui des travaux du domaine
- Jeu de données préparé par C. Geourjon (IBCP, Lyon)
- Nombreuses séries (rayon des fenêtres, codage)
- Comparaison avec un choix aléatoire des ponts

Nombre de ponts par protéine	Choix aléatoire des ponts	Performances avec NB	Performances avec NBSSA-EM
2	33.3%	40.2%	<b>58.8%</b>
3	20%	17.5%	<b>33.4%</b>
4	14.3%	12.7%	<b>16.3%</b>
5	11.1%	5.8%	<b>13.2%</b>

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Expériences sur données ponts disulfures

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Description

- Protocole identique à celui des travaux du domaine
- Jeu de données préparé par C. Geourjon (IBCP, Lyon)
- Nombreuses séries (rayon des fenêtres, codage)
- Comparaison avec un choix aléatoire des ponts

## Conclusions

- Résultats encourageants, mais...
- $\neq$  non validées par un test statistique avec grande confiance
- Ne permettent pas de valider notre hypothèse
- Ne montrent pas qu'une information ait été détectée  
⇒ la question de l'existence d'une information locale  
impliquée dans la formation de ponts doit être étudiée

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## *II*

# *La question de l'existence d'une information locale impliquée dans les appariements d'acides aminés*

### *Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

### *Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

### *Information Locale*

*1ère approche*

*Modèle proposé*

### *Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

### *Expérimentation du protocole*

### *Conclusion*

*Conclusions*

*Perspectives*

## Répondre aux questions

- Les environnements locaux d'acides aminés appariés jouent-ils un rôle dans la formation de ponts ?
- Existe-il des affinités + ou - fortes entre ces contextes locaux ?
- Comment le prouver ?

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

1ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Répondre aux questions

- Les environnements locaux d'acides aminés appariés jouent-ils un rôle dans la formation de ponts ?
- Existe-il des affinités + ou - fortes entre ces contextes locaux ?
- Comment le prouver ?

## Intérêt

Savoir si cette information est pertinente pour prédire les ponts

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Notion d'affinité entre paires d'environnements locaux

- $\Omega_r = \Sigma^{2r+1} = \{\text{segments de protéines de taille } 2r + 1\}$
- $P(B(w, w')|w, w', n)$  : probabilité que  $w$  et  $w'$  soient appariés sachant que ce sont des environnements locaux d'a.a. d'une protéine avec  $n$  ponts

## Notion d'affinité entre paires d'environnements locaux

- $\Omega_r = \Sigma^{2r+1} = \{\text{segments de protéines de taille } 2r + 1\}$
- $P(B(w, w')|w, w', n)$  : probabilité que  $w$  et  $w'$  soient appariés sachant que ce sont des environnements locaux d'a.a. d'une protéine avec  $n$  ponts

## Une première approche de l'information locale

- Considérons des protéines à  $n$  ponts :

$$P(B(w, w')|w, w', n) = \frac{1}{2^{n-1}} \Leftrightarrow \text{pas d'information locale}$$

## Notion d'affinité entre paires d'environnements locaux

- $\Omega_r = \Sigma^{2r+1} = \{\text{segments de protéines de taille } 2r + 1\}$
- $P(B(w, w')|w, w', n)$  : probabilité que  $w$  et  $w'$  soient appariés sachant que ce sont des environnements locaux d'a.a. d'une protéine avec  $n$  ponts

## Une première approche de l'information locale

- Considérons des protéines à  $n$  ponts :

$$P(B(w, w')|w, w', n) = \frac{1}{2^{n-1}} \Leftrightarrow \text{pas d'information locale}$$

- Méthode statistique simple pour décider si une information locale existe
- Estimation directe de ces probabilités impossible :  
avec  $r = 3 \rightarrow |\{(w, w'), w, w' \in \Omega_r\}| = 20^{12} \simeq 4 \cdot 10^{15}$  !
- Seules quelques centaines d'exemples disponibles...

# Une approche simplificatrice et raisonnable

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Idée

- Il n'est pas nécessaire de connaître  $P(B(w, w')|w, w', n)$
- On veut montrer que certaines paires ont une propension plus forte à se retrouver appariées par leurs acides aminés centraux que d'autres

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une approche simplificatrice et raisonnable

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Idée

- Il n'est pas nécessaire de connaître  $P(B(w, w')|w, w', n)$
- On veut montrer que certaines paires ont une propension plus forte à se retrouver appariées par leurs acides aminés centraux que d'autres

## Solution proposée : une fonction d'affinité

- Supposer l'existence d'une fonction  $g : \Omega_T^2 \rightarrow \mathcal{Y}$  avec  $|\mathcal{Y}|$  petit

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une approche simplificatrice et raisonnable

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Idée

- Il n'est pas nécessaire de connaître  $P(B(w, w')|w, w', n)$
- On veut montrer que certaines paires ont une propension plus forte à se retrouver appariées par leurs acides aminés centraux que d'autres

## Solution proposée : une fonction d'affinité

- Supposer l'existence d'une fonction  $g : \Omega_T^2 \rightarrow \mathcal{Y}$  avec  $|\mathcal{Y}|$  petit
- $g$  « regroupe » les paires  $(w, w')$  similaires :

$$g(w_1, w_2) = g(w'_1, w'_2) \Rightarrow P(B(w_1, w_2)|w_1, w_2, n) \simeq P(B(w'_1, w'_2)|w'_1, w'_2, n)$$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une approche simplificatrice et raisonnable

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Idée

- Il n'est pas nécessaire de connaître  $P(B(w, w')|w, w', n)$
- On veut montrer que certaines paires ont une propension plus forte à se retrouver appariées par leurs acides aminés centraux que d'autres

## Solution proposée : une fonction d'affinité

- Supposer l'existence d'une fonction  $g : \Omega_T^2 \rightarrow \mathcal{Y}$  avec  $|\mathcal{Y}|$  petit
- $g$  « regroupe » les paires  $(w, w')$  similaires :

$$g(w_1, w_2) = g(w'_1, w'_2) \Rightarrow P(B(w_1, w_2)|w_1, w_2, n) \simeq P(B(w'_1, w'_2)|w'_1, w'_2, n)$$

- en niveaux d'affinité :

$$y < y' \Rightarrow P(B(w_1, w_2)|g(w_1, w_2) = y) < P(B(w'_1, w'_2)|g(w'_1, w'_2) = y')$$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une approche simplificatrice et raisonnable

## Idée

- Il n'est pas nécessaire de connaître  $P(B(w, w')|w, w', n)$
- On veut montrer que certaines paires ont une propension plus forte à se retrouver appariées par leurs acides aminés centraux que d'autres

## Solution proposée : une fonction d'affinité

- Supposer l'existence d'une fonction  $g : \Omega_T^2 \rightarrow \mathcal{Y}$  avec  $|\mathcal{Y}|$  petit
- $g$  « regroupe » les paires  $(w, w')$  similaires :

$$g(w_1, w_2) = g(w'_1, w'_2) \Rightarrow P(B(w_1, w_2)|w_1, w_2, n) \simeq P(B(w'_1, w'_2)|w'_1, w'_2, n)$$

- en niveaux d'affinité :

$$y < y' \Rightarrow P(B(w_1, w_2)|g(w_1, w_2) = y) < P(B(w'_1, w'_2)|g(w'_1, w'_2) = y')$$

- Dans ce cas, seules les  $P(B(w, w')|g(w, w') = y, n)$  sont à étudier
- L'équivalence donnée dans la première approche reste valable

## Introduction

Protéines et structure

Modélisation de novo

Classification

## Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

## Information Locale

1ère approche

Modèle proposé

## Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

## Expérimentation du protocole

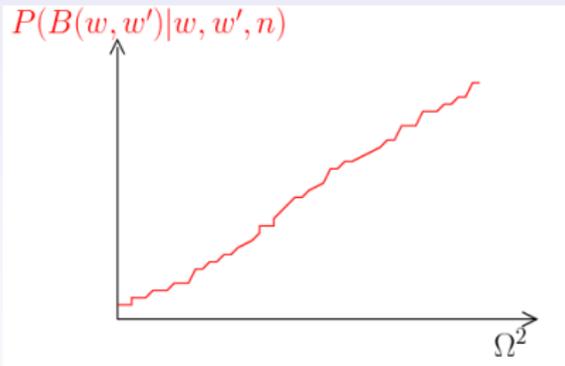
## Conclusion

Conclusions

Perspectives

# Cas le plus simple : $\mathcal{Y} = \{0, 1\}$

## Conséquences



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

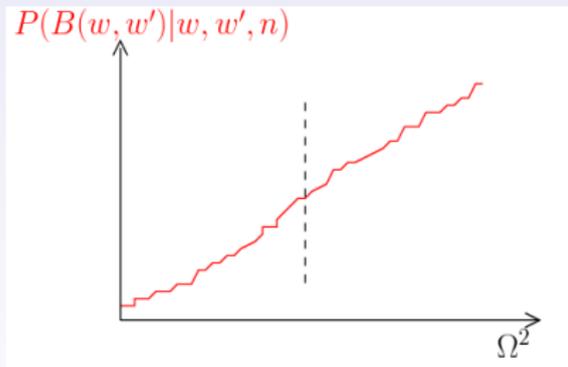
Conclusions

Perspectives

# Cas le plus simple : $\mathcal{Y} = \{0, 1\}$

## Conséquences

- Les paires  $(w, w')$  sont partitionnées en deux classes

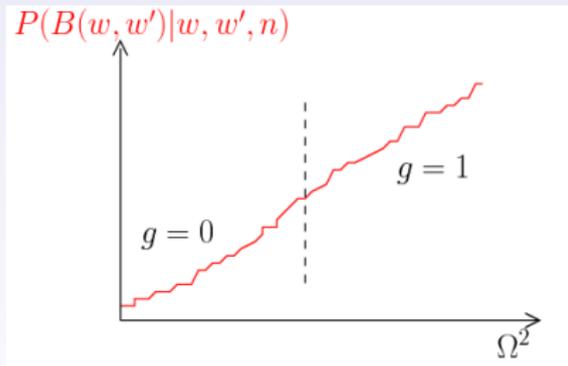


$$g(w_1, w_2) = g(w'_1, w'_2) \Rightarrow P(B(w_1, w_2)|w_1, w_2, n) \simeq P(B(w'_1, w'_2)|w'_1, w'_2, n)$$

# Cas le plus simple : $\mathcal{Y} = \{0, 1\}$

## Conséquences

- Les paires  $(w, w')$  sont partitionnées en deux classes
- Chaque classe correspond à un niveau d'affinité

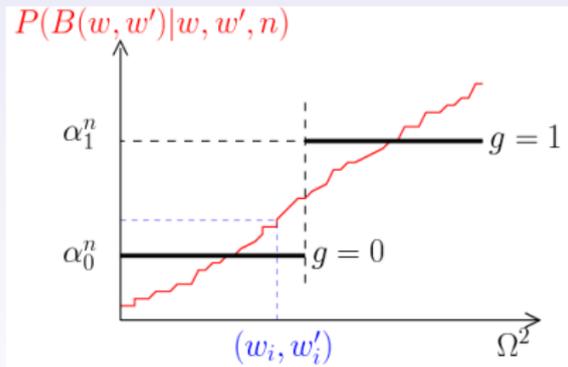


$$y < y' \Rightarrow P(B(w_1, w_2)|g(w_1, w_2) = y) < P(B(w'_1, w'_2)|g(w'_1, w'_2) = y')$$

# Cas le plus simple : $\mathcal{Y} = \{0, 1\}$

## Conséquences

- Les paires  $(w, w')$  sont partitionnées en deux classes
- Chaque classe correspond à un niveau d'affinité

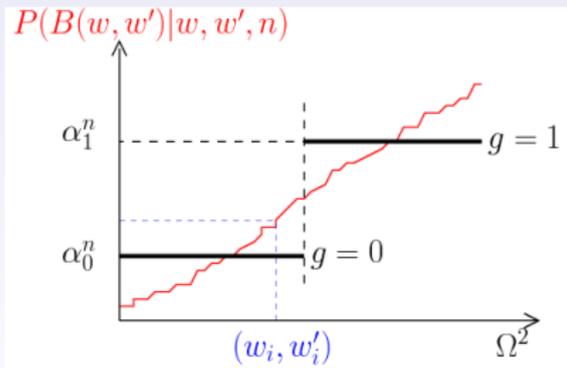


$$P(B(w, w') | g(w, w'), n) = \begin{cases} \alpha_1^n & \text{if } g(w, w') = 1 \\ \alpha_0^n & \text{if } g(w, w') = 0 \end{cases}$$

# Cas le plus simple : $\mathcal{Y} = \{0, 1\}$

## Conséquences

- Les paires  $(w, w')$  sont partitionnées en deux classes
- Chaque classe correspond à un niveau d'affinité



Si une information locale existe : on doit avoir  $\alpha_1^n > \alpha_0^n$   
Dans le cas contraire :  $\alpha_1^n = \alpha_0^n = \frac{1}{2n-1}$

# Propriétés induites par $g$

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Une fonction accessible, mais pas directement

- Chaque paire  $(w, w')$  n'appartient qu'à une seule classe attribuée par  $g$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

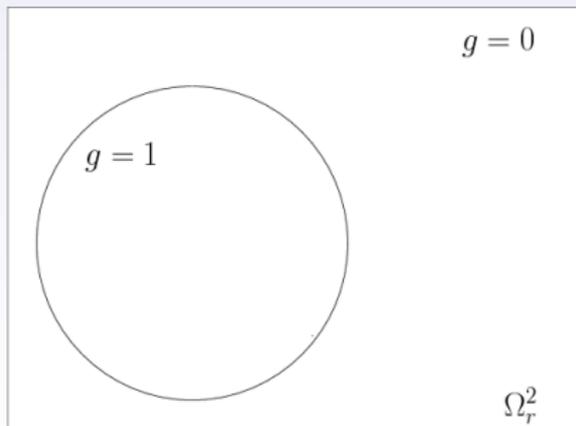
Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

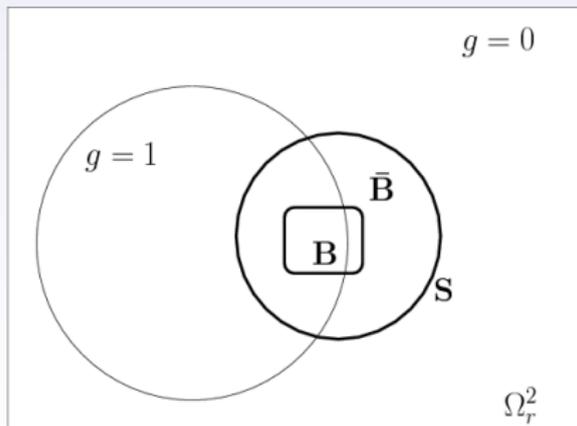
Perspectives



# Propriétés induites par $g$

## Une fonction accessible, mais pas directement

- Chaque paire  $(w, w')$  n'appartient qu'à une seule classe attribuée par  $g$
- Les observations dont on dispose (paires appariées et non appariées) en fournissent alors une vue indirecte



# Propriétés induites par $g$

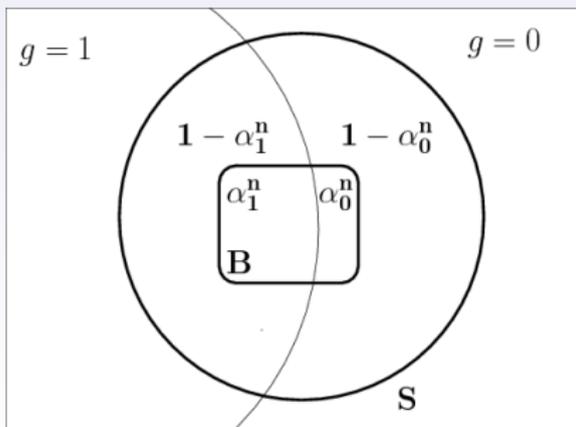
Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Une fonction accessible, mais pas directement

- Chaque paire  $(w, w')$  n'appartient qu'à une seule classe attribuée par  $g$
- Les observations dont on dispose (paires appariées et non appariées) en fournissent alors une vue indirecte

$$P(B(w, w')|g(w, w'), n) = \begin{cases} \alpha_1^n & \text{if } g(w, w') = 1 \\ \alpha_0^n & \text{if } g(w, w') = 0 \end{cases}$$



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Propriétés induites par $g$

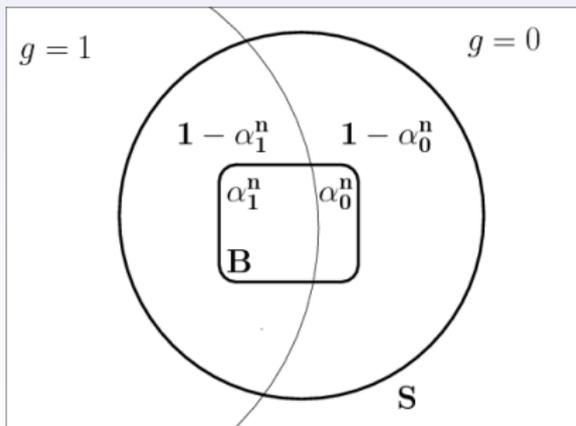
Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Une fonction accessible, mais pas directement

- Chaque paire  $(w, w')$  n'appartient qu'à une seule classe attribuée par  $g$
- Les observations dont on dispose (paires appariées et non appariées) en fournissent alors une vue indirecte

$$\begin{cases} g = 1 \text{ correspond aux ponts observés avec un bruit } \eta^+ = 1 - \alpha_1^n \\ g = 0 \text{ correspond aux paires non appariées avec bruit } \eta^- = \alpha_0^n \end{cases}$$



Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Prouver l'existence d'une information locale

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Modèle de bruit de classification induit

- Généralisation du modèle de bruit de classification CN
- Le taux de bruit est conditionnel à chaque classe
- **Bruit de classification conditionnel à chaque classe (CCCN)**

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Prouver l'existence d'une information locale

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Modèle de bruit de classification induit

- Généralisation du modèle de bruit de classification CN
- Le taux de bruit est conditionnel à chaque classe
- **Bruit de classification conditionnel à chaque classe (CCCN)**

## Détecter la présence d'une information locale

Si une information locale existe

Si elle est représentable par une fonction apprenable en contexte CCCN

Alors, on doit pouvoir la détecter, l'extraire et l'évaluer

## Littérature sur ce modèle de bruit

- Une seule brève référence à ce modèle dans [Blum et Mitchell, 1998]
- Aucun résultat et aucune connaissance sur ce modèle de bruit

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

1ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

# Apprentissage avec bruit CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Littérature sur ce modèle de bruit

- Une seule brève référence à ce modèle dans [Blum et Mitchell, 1998]
- Aucun résultat et aucune connaissance sur ce modèle de bruit

## Le double intérêt d'une étude de contexte d'apprentissage

- Elle permettrait l'application du protocole proposé
- Contribution intéressante au domaine de l'apprentissage

# *III*

## *Etude de l'apprentissage supervisé en présence de bruit de classification CCCN*

*Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

*Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

*Information Locale*

*1ère approche*

*Modèle proposé*

*Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

*Expérimentation du  
protocole*

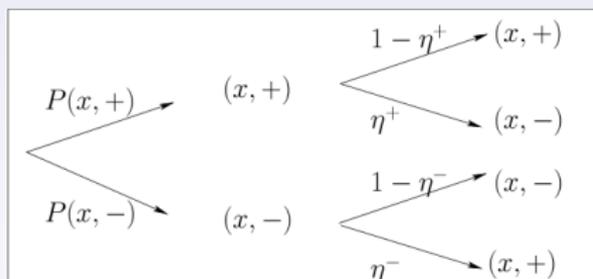
*Conclusion*

*Conclusions*

*Perspectives*

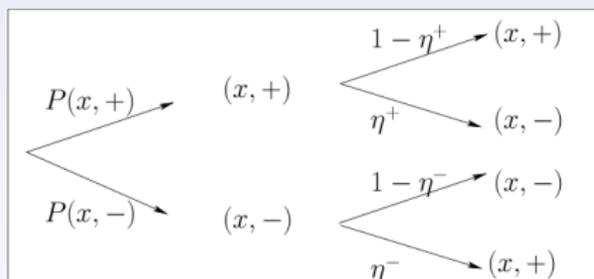
## Classification supervisée avec bruit CCCN

- $S^\eta = \{(x_1, y_1^\eta), \dots, (x_l, y_l^\eta)\}$
- Les exemples de  $S^\eta$  sont distribués selon la distribution  $P^\eta$
- $\eta^+ + \eta^- < 1$  pour lever toute ambiguïté



## Classification supervisée avec bruit CCCN

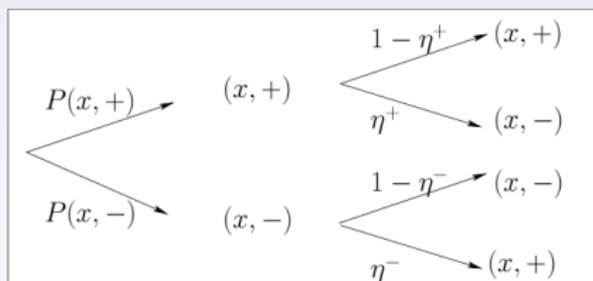
- $S^\eta = \{(x_1, y_1^\eta), \dots, (x_l, y_l^\eta)\}$
- Les exemples de  $S^\eta$  sont distribués selon la distribution  $P^\eta$
- $\eta^+ + \eta^- < 1$  pour lever toute ambiguïté



$$\begin{cases} P^\eta(x, +) = (1 - \eta^+) \cdot P(x, +) + \eta^- \cdot P(x, -) \\ P^\eta(x, -) = \eta^+ \cdot P(x, +) + (1 - \eta^-) \cdot P(x, -) \end{cases}$$

## Classification supervisée avec bruit CCCN

- $S^\eta = \{(x_1, y_1^\eta), \dots, (x_l, y_l^\eta)\}$
- Les exemples de  $S^\eta$  sont distribués selon la distribution  $P^\eta$
- $\eta^+ + \eta^- < 1$  pour lever toute ambiguïté



$$\begin{cases} P^\eta(x, +) = (1 - \eta^+) \cdot P(x, +) + \eta^- \cdot P(x, -) \\ P^\eta(x, -) = \eta^+ \cdot P(x, +) + (1 - \eta^-) \cdot P(x, -) \end{cases}$$

### Objectif

Calculer  $f$  qui minimise  $R(f)$  relativement à la distribution originale  $P$

# Classification supervisée avec bruit CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Etude du problème sans hypothèse sur $P$

- On cherche à minimiser :

$$R(f) = \frac{R^\eta(f) - \eta^+ \cdot p - \eta^- \cdot (1 - p)}{1 - \eta^- - \eta^+}$$

- avec  $R^\eta(f) = P^\eta(f(x) \neq y)$  et  $p = P(f(x) = +)$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Etude du problème sans hypothèse sur $P$

- On cherche à minimiser :

$$R(f) = \frac{R^\eta(f) - \eta^+ \cdot p - \eta^- \cdot (1 - p)}{1 - \eta^- - \eta^+}$$

- avec  $R^\eta(f) = P^\eta(f(x) \neq y)$  et  $p = P(f(x) = +)$
- Ne correspond pas forcément à minimiser  $R^\eta(f)$

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

1ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Etude du problème sans hypothèse sur $P$

- On cherche à minimiser :

$$R(f) = \frac{R^\eta(f) - \eta^+ \cdot p - \eta^- \cdot (1 - p)}{1 - \eta^- - \eta^+}$$

- avec  $R^\eta(f) = P^\eta(f(x) \neq y)$  et  $p = P(f(x) = +)$
- Ne correspond pas forcément à minimiser  $R^\eta(f)$
- Différence importante avec le modèle CN ( $\eta^+ = \eta^- = \eta < 0.5$ )

$$R(f) = \frac{R^\eta(f) - \eta}{1 - 2\eta}$$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Etude du problème sans hypothèse sur $P$

- On cherche à minimiser :

$$R(f) = \frac{R^\eta(f) - \eta^+ \cdot p - \eta^- \cdot (1 - p)}{1 - \eta^- - \eta^+}$$

- avec  $R^\eta(f) = P^\eta(f(x) \neq y)$  et  $p = P(f(x) = +)$
- Ne correspond pas forcément à minimiser  $R^\eta(f)$
- Différence importante avec le modèle CN ( $\eta^+ = \eta^- = \eta < 0.5$ )

$$R(f) = \frac{R^\eta(f) - \eta}{1 - 2\eta}$$

- Peut être impossible si les  $\eta^+$  et  $\eta^-$  sont inconnus

### Introduction

Protéines et structure  
Modélisation de novo  
Classification

### Ponts Disulfures

Modélisation  
App. semi-sup. asym.  
Expériences

### Information Locale

1ère approche  
Modèle proposé

### Etude cadre CCCN

Cas général  
Distr. Produits  
Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions  
Perspectives

# Classification supervisée avec bruit CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Etude du problème sans hypothèse sur $P$

- On cherche à minimiser :

$$R(f) = \frac{R^\eta(f) - \eta^+ \cdot p - \eta^- \cdot (1 - p)}{1 - \eta^- - \eta^+}$$

- avec  $R^\eta(f) = P^\eta(f(x) \neq y)$  et  $p = P(f(x) = +)$
- Ne correspond pas forcément à minimiser  $R^\eta(f)$
- Différence importante avec le modèle CN ( $\eta^+ = \eta^- = \eta < 0.5$ )

$$R(f) = \frac{R^\eta(f) - \eta}{1 - 2\eta}$$

- Peut être impossible si les  $\eta^+$  et  $\eta^-$  sont inconnus

## Théorème

Le problème est mal posé

[Denis, Magnan et Ralaivola, CAp 2006, ICML 2006]

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une première condition d'identifiabilité de $P$

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Toutefois

- Dans certains cas, la distribution  $P^\eta \Rightarrow P$
- Dans ces cas, le problème devient bien posé

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Une première condition d'identifiabilité de $\mathcal{P}$

## Toutefois

- Dans certains cas, la distribution  $P^\eta \Rightarrow P$
- Dans ces cas, le problème devient bien posé

## Proposition

Soient  $\mathcal{P}$  un ensemble de distributions sur  $\mathcal{X} \times \mathcal{Y}$ ,  
 $\mathcal{Q} = \{P(\cdot|y) | y = - \text{ ou } y = +, P \in \mathcal{P}\}$ . Si les 2-mélanges de  $\mathcal{Q}$   
sont identifiables, alors  $\mathcal{P}$  est identifiable avec bruit CCCN

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

Ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

# Une première condition d'identifiabilité de $\mathcal{P}$

## Toutefois

- Dans certains cas, la distribution  $P^\eta \Rightarrow P$
- Dans ces cas, le problème devient bien posé

## Proposition

Soient  $\mathcal{P}$  un ensemble de distributions sur  $\mathcal{X} \times \mathcal{Y}$ ,  
 $\mathcal{Q} = \{P(\cdot|y) | y = - \text{ ou } y = +, P \in \mathcal{P}\}$ . Si les 2-mélanges de  $\mathcal{Q}$   
sont identifiables, alors  $\mathcal{P}$  est identifiable avec bruit CCCN

## Corollaires

- Mélanges de distributions produits identifiables

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

1ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

# Une première condition d'identifiabilité de $\mathcal{P}$

## Toutefois

- Dans certains cas, la distribution  $P^\eta \Rightarrow P$
- Dans ces cas, le problème devient bien posé

## Proposition

Soient  $\mathcal{P}$  un ensemble de distributions sur  $\mathcal{X} \times \mathcal{Y}$ ,  
 $\mathcal{Q} = \{P(\cdot|y)|y = - \text{ ou } y = +, P \in \mathcal{P}\}$ . Si les 2-mélanges de  $\mathcal{Q}$   
sont identifiables, alors  $\mathcal{P}$  est identifiable avec bruit CCCN

## Corollaires

- Mélanges de distributions produits identifiables
- Classifieurs naïfs de Bayes déterminés par  $P^\eta$

[Denis, Magnan et Ralaivola, CAp 2006, ICML 2006]

## Mélanges de distributions produits

- Expressions analytiques des coefficients de mélange
- Elles permettent :
  - de retrouver l'expression analytique de  $P(+)$  obtenue en contexte semi-supervisé asymétrique
  - d'obtenir une expression analytique des paramètres des classifieurs naïfs de Bayes

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Mélanges de distributions produits

- Expressions analytiques des coefficients de mélange
- Elles permettent :
  - de retrouver l'expression analytique de  $P(+)$  obtenue en contexte semi-supervisé asymétrique
  - d'obtenir une expression analytique des paramètres des classifieurs naïfs de Bayes

## NB-CCCN Algorithme Naïf de Bayes en contexte CCCN

- Estimateurs des paramètres déduits des formules précédentes
- **Sortie** :  $\hat{\theta}$ , une estimation consistante de  $\theta$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Mélanges de distributions produits

- Expressions analytiques des coefficients de mélange
- Elles permettent :
  - de retrouver l'expression analytique de  $P(+)$  obtenue en contexte semi-supervisé asymétrique
  - d'obtenir une expression analytique des paramètres des classifieurs naïfs de Bayes

## NB-CCCN Algorithme Naïf de Bayes en contexte CCCN

- Estimateurs des paramètres déduits des formules précédentes
- **Sortie** :  $\hat{\theta}$ , une estimation consistante de  $\theta$

## NB-CCCN-EM NB-CCCN + Méthode E.M.

- **Valeurs manquantes** : quelles données sont corrompues ?
- Modèle initial  $\theta_0$  obtenu avec NB-CCCN
- Formules de calcul des paramètres de  $\theta_n$

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Le problème d'évaluation des modèles inférés

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Mangan

## Comment évaluer les classifieurs calculés ?

- Données d'apprentissage sont corrompues par du bruit CCCN
- Des données test devraient également l'être
- Or, dans ce cas, elles n'attestent pas de la qualité des modèles
- Conséquence directe de l'inconsistance du principe ERM  
⇒ question laissée ouverte par nos travaux

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Le problème d'évaluation des modèles inférés

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Comment évaluer les classifieurs calculés ?

- Données d'apprentissage sont corrompues par du bruit CCCN
- Des données test devraient également l'être
- Or, dans ce cas, elles n'attestent pas de la qualité des modèles
- Conséquence directe de l'inconsistance du principe ERM  
⇒ question laissée ouverte par nos travaux

## Expériences sur données artificielles et UCI

- Evaluation sur des données non corrompues
- Le bruit CCCN peut efficacement être éliminé
- Les algorithmes permettent d'obtenir de bonnes estimations des modèles naïfs de Bayes

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

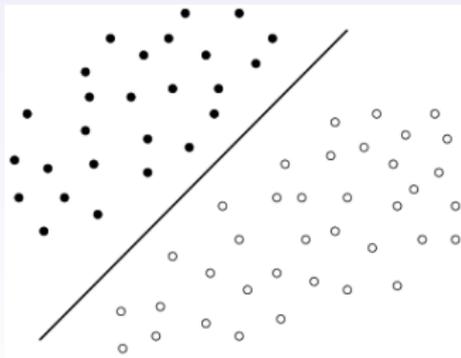
Conclusion

Conclusions

Perspectives

## Description sommaire

- $\mathcal{X} = \mathbb{R}^m$ ,  $\mathcal{Y} = \{+, -\}$
- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$
- Un hyperplan  $H$  sépare  $S$  si les données positives et négatives de  $S$  se trouvent de part et d'autre de  $H$



## Introduction

Protéines et structure  
Modélisation de novo  
Classification

## Ponts Disulfures

Modélisation  
App. semi-sup. asym.  
Expériences

## Information Locale

1ère approche  
Modèle proposé

## Etude cadre CCCN

Cas général  
Distr. Produits  
Séparateurs Linéaires

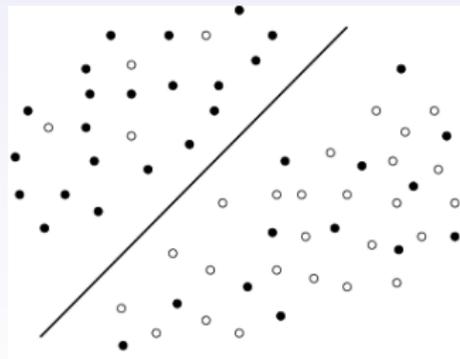
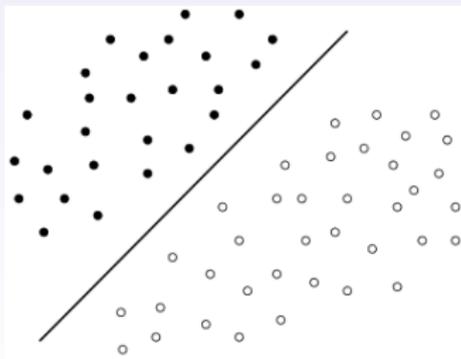
## Expérimentation du protocole

## Conclusion

Conclusions  
Perspectives

## Description sommaire

- $\mathcal{X} = \mathbb{R}^m$ ,  $\mathcal{Y} = \{+, -\}$
- $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$
- Un hyperplan  $H$  sépare  $S$  si les données positives et négatives de  $S$  se trouvent de part et d'autre de  $H$
- **Peut-on apprendre ces séparateurs en présence de bruit CCCN ?**



## Introduction

Protéines et structure  
Modélisation de novo  
Classification

## Ponts Disulfures

Modélisation  
App. semi-sup. asym.  
Expériences

## Information Locale

1ère approche  
Modèle proposé

## Etude cadre CCCN

Cas général  
Distr. Produits  
Séparateurs Linéaires

## Expérimentation du protocole

## Conclusion

Conclusions  
Perspectives

## Algorithme du perceptron

**Entrée :**  $S$ , séparable par un hyperplan  $w^*$

$$w = \vec{0}$$

**Tant que**  $\exists(x, y) \in S$  tel que  $w \cdot yx < 0$  **faire**

$$x_{upd} = yx \text{ tel que } w \cdot yx < 0$$

$$w = w + x_{upd}$$

**Fin Tant que**

**Sortie :**  $w$ , qui sépare  $S$

## Propriétés

- Exponentiel dans le pire des cas
- Généralement efficace et performant en pratique
- Même face aux séparateurs linéaires optimaux [Graepel et al., 2001]

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Résultats obtenus dans le cadre CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Bruits $\eta^+$ et $\eta^-$ connus

- On peut estimer la somme des exemples mal classés par le  $w$  courant
- C'est un bon vecteur de mise à jour du perceptron [Blum et al., 1996]

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Résultats obtenus dans le cadre CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Bruits $\eta^+$ et $\eta^-$ connus

- On peut estimer la somme des exemples mal classés par le  $w$  courant
- C'est un bon vecteur de mise à jour du perceptron [Blum et al., 1996]

## Bruits $\eta^+$ et $\eta^-$ inconnus

- Tester différentes valeurs pour  $\eta^+$  et  $\eta^-$  ( $\eta^+ + \eta^- < 1$ )
- Apprendre une hypothèse avec chacun de ces taux de bruit
- Comment sélectionner une bonne hypothèse ?

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Résultats obtenus dans le cadre CCCN

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Bruits $\eta^+$ et $\eta^-$ connus

- On peut estimer la somme des exemples mal classés par le  $w$  courant
- C'est un bon vecteur de mise à jour du perceptron [Blum et al., 1996]

## Bruits $\eta^+$ et $\eta^-$ inconnus

- Tester différentes valeurs pour  $\eta^+$  et  $\eta^-$  ( $\eta^+ + \eta^- < 1$ )
- Apprendre une hypothèse avec chacun de ces taux de bruit
- Comment sélectionner une bonne hypothèse ?

## Nous montrons ...

Qu'il existe un critère de sélection consistant pour les séparateurs linéaires

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

Ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Résultats obtenus dans le cadre CCCN

## Bruits $\eta^+$ et $\eta^-$ connus

- On peut estimer la somme des exemples mal classés par le  $w$  courant
- C'est un bon vecteur de mise à jour du perceptron [Blum et al., 1996]

## Bruits $\eta^+$ et $\eta^-$ inconnus

- Tester différentes valeurs pour  $\eta^+$  et  $\eta^-$  ( $\eta^+ + \eta^- < 1$ )
- Apprendre une hypothèse avec chacun de ces taux de bruit
- Comment sélectionner une bonne hypothèse?

## Nous montrons ...

Qu'il existe un critère de sélection consistant pour les séparateurs linéaires

## Importance de ce résultat

- On obtient un algorithme du perceptron en contexte CCCN
- Premier cas pour lequel nous avons pu établir un tel critère d'induction

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## *IV*

# *Première expérimentation du protocole de détection d'affinités locales*

### *Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

### *Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

### *Information Locale*

*1ère approche*

*Modèle proposé*

### *Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

### *Expérimentation du protocole*

### *Conclusion*

*Conclusions*

*Perspectives*

# Expérimentations sur des données biologiques

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Rappels

- Environnements locaux impliqués dans la formation de ponts ?
- Nous avons proposé de chercher une fonction d'affinité
- Algorithmes tolérants au bruit CCCN nécessaires pour les apprendre

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Expérimentations sur des données biologiques

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Rappels

- Environnements locaux impliqués dans la formation de ponts ?
- Nous avons proposé de chercher une fonction d'affinité
- Algorithmes tolérants au bruit CCCN nécessaires pour les apprendre

## Algorithme utilisé pour chercher une fonction d'affinité

- L'algorithme du perceptron CCCN

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

# Expérimentations sur des données biologiques

Apprentissage pour  
l'étude des  
interactions entre  
acides aminés

Christophe Magnan

## Rappels

- Environnements locaux impliqués dans la formation de ponts ?
- Nous avons proposé de chercher une fonction d'affinité
- Algorithmes tolérants au bruit CCCN nécessaires pour les apprendre

## Algorithme utilisé pour chercher une fonction d'affinité

- L'algorithme du perceptron CCCN

## Jeu de données Ponts Salins

- Développé par C. Geourjon (IBCP, Lyon)
- 1688 protéines - 7594 ponts salins

## Jeu de données Ponts Disulfures

- Développé par J. Cheng (UCI, Californie)
- 1018 protéines - 2541 ponts disulfures

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

1ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

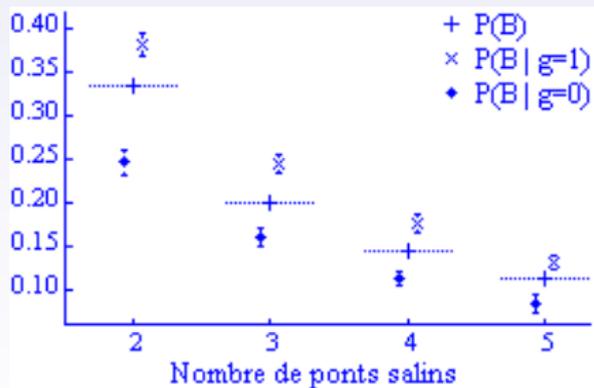
Conclusions

Perspectives

# Résultats sur les données ponts salins

## Une information locale clairement détectée

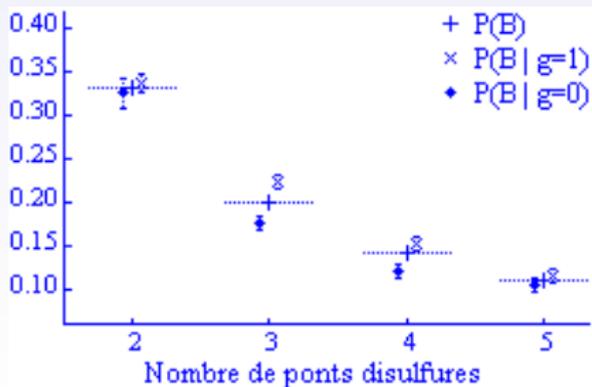
- Les fonctions  $g$  apprises montrent qu'un signal clair est détecté
- Ces fonctions sont toujours telles que  $P(B|g = 1) > P(B|g = 0)$
- Il y a une information locale impliquée dans la formation de ces ponts
- Non corrélée à la structure secondaire



# Résultats sur les données ponts disulfures

## Un signal trop faible pour conclure

- Quel que soit le nombre de ponts,  $P(B|g = 1) \simeq P(B|g = 0)$
- De nombreuses explications possibles :
  - Réalité biologique
  - Classe de séparateurs trop peu expressive
  - Manque de données
  - ....
- Ces expériences ne permettent pas de dire lesquelles sont les + probables



## *Prédiction des contacts entre acides aminés*

- Première étude sur l'existence d'une information locale
- Un protocole de détection de l'affinité locale
- Montre l'existence de cette information pour les ponts salins
- Le cas des ponts disulfures reste ouvert

*Introduction*

*Protéines et structure*

*Modélisation de novo*

*Classification*

*Ponts Disulfures*

*Modélisation*

*App. semi-sup. asym.*

*Expériences*

*Information Locale*

*ère approche*

*Modèle proposé*

*Etude cadre CCCN*

*Cas général*

*Distr. Produits*

*Séparateurs Linéaires*

*Expérimentation du  
protocole*

*Conclusion*

*Conclusions*

*Perspectives*

## Prédiction des contacts entre acides aminés

- Première étude sur l'existence d'une information locale
- Un protocole de détection de l'affinité locale
- Montre l'existence de cette information pour les ponts salins
- Le cas des ponts disulfures reste ouvert

## Apprentissage automatique

- Etude du contexte semi-supervisé asymétrique
- Introduction de l'apprentissage avec bruit CCCN
- Résultats d'identifiabilité dans ce contexte
- Des algorithmes d'apprentissage efficaces dans ce contexte

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Prédiction des contacts entre acides aminés

- Première étude sur l'existence d'une information locale
- Un protocole de détection de l'affinité locale
- Montre l'existence de cette information pour les ponts salins
- Le cas des ponts disulfures reste ouvert

## Apprentissage automatique

- Etude du contexte semi-supervisé asymétrique
- Introduction de l'apprentissage avec bruit CCCN
- Résultats d'identifiabilité dans ce contexte
- Des algorithmes d'apprentissage efficaces dans ce contexte

## Une plateforme logicielle Java : NoTALAP

- Implémentation du protocole de détection d'affinités locales

Introduction

Protéines et structure

Modélisation de novo

Classification

Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

Information Locale

ère approche

Modèle proposé

Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

Expérimentation du  
protocole

Conclusion

Conclusions

Perspectives

## Prédiction des contacts entre acides aminés

- Ne pas séparer les protéines par nombre de ponts
- Intégrer la fonction d'affinité  $g$  dans la prédiction des contacts

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

1ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Prédiction des contacts entre acides aminés

- Ne pas séparer les protéines par nombre de ponts
- Intégrer la fonction d'affinité  $g$  dans la prédiction des contacts

## Apprentissage automatique

- D'autres classes de fonctions apprenables en contexte CCCN
- Méthodes à noyaux ? → noyaux de paires de fenêtres
- Comment montrer que des données sont CCCN ?
- Un critère inductif consistant pour toute méthode ?
- Comment évaluer les classifieurs sur des données bruitées ?

### Introduction

Protéines et structure

Modélisation de novo

Classification

### Ponts Disulfures

Modélisation

App. semi-sup. asym.

Expériences

### Information Locale

Ère approche

Modèle proposé

### Etude cadre CCCN

Cas général

Distr. Produits

Séparateurs Linéaires

### Expérimentation du protocole

### Conclusion

Conclusions

Perspectives

## Conférences internationales

- [ICML 2006] François Denis, Christophe N. Magnan, Liva Ralaivola  
*"Efficient Learning of NB Classifiers under Class-Conditional Classification Noise"*
- [ICML 2006] Liva Ralaivola, François Denis, Christophe N. Magnan *"CN=CPCN"*
- [BIBM 2007] Christophe N. Magnan, Cécile Capponi, François Denis  
*"A Protocol to Detect Local Affinities Involved in Proteins Distant Interactions"*

## Conférences nationales

- [CAp 2005] Christophe N. Magnan *"Apprentissage semi-supervisé asymétrique et estimation d'affinités locales dans les protéines"*
- [CAp 2006] François Denis, Christophe N. Magnan, Liva Ralaivola  
*"Apprentissage de classifieurs naïfs de Bayes à partir de données soumises à un bruit de classification conditionnel à chaque classe"*
- [CAp 2006] Liva Ralaivola, François Denis, Christophe N. Magnan  
*"Bruits de classification constant et constant par morceaux : égalité des ensembles de classes de concepts apprenables"*
- [CAp 2007] Christophe N. Magnan, Cécile Capponi, François Denis  
*"Un protocole de détection d'affinités locales dans les protéines"*

## Revue Nationale

- [Revue R.I.A., Volume 20, Num 6, 11/2006] Christophe N. Magnan  
*"Asymmetrical Semi-Supervised Learning and Prediction of Disulfide Connectivity in Proteins"*