



**POLYTECHNIQUE  
MONTRÉAL**

UNIVERSITÉ  
D'INGÉNIERIE



# Apprentissage Profond des Caractéristiques Structurelles et Historiques des Systèmes pour la Détection d'Anti-patterns

**Antoine Barbez**

Présentation de fin de maîtrise

Département de génie informatique et génie logiciel

École polytechnique de Montréal

Dirigé par:

Foutse Khomh

Yann-Gaël Guéhéneuc

13 Décembre 2018

- Définition du problème
- L'apprentissage supervisé
- Approche générale
- Première architecture: SMAD
- Deuxième architecture: CAME
- Conclusion



## Comment fixer les roues à l'essieu?

- ✓ Avec des vis
- ✗ Avec une soudure



*« ... one object with a lion's share of the responsibilities, while most other objects only hold data or execute simple processes. »*

*Brown et al. (1998)*

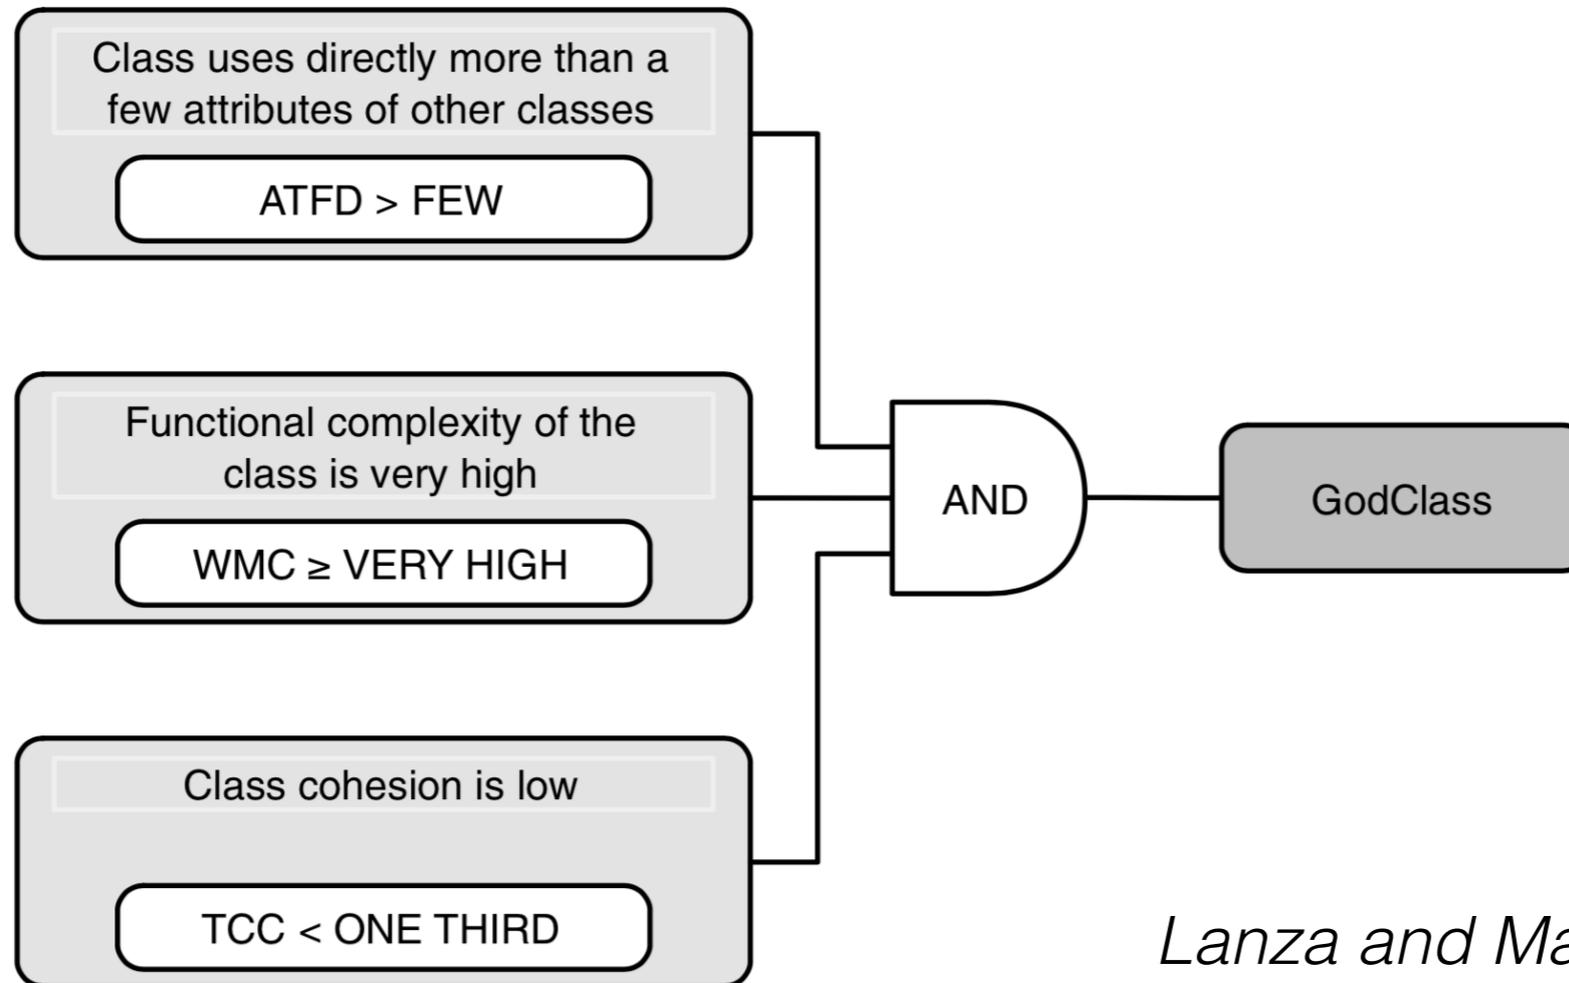
- Viole le principe de responsabilité unique

« *A method that seems more interested in a class other than the one it actually is in* »

*Fowler (1999)*

- Symptôme qu'une méthode est implémentée dans la mauvaise classe
- Beaucoup d'accès aux données de la classe enviée

- Rule Card

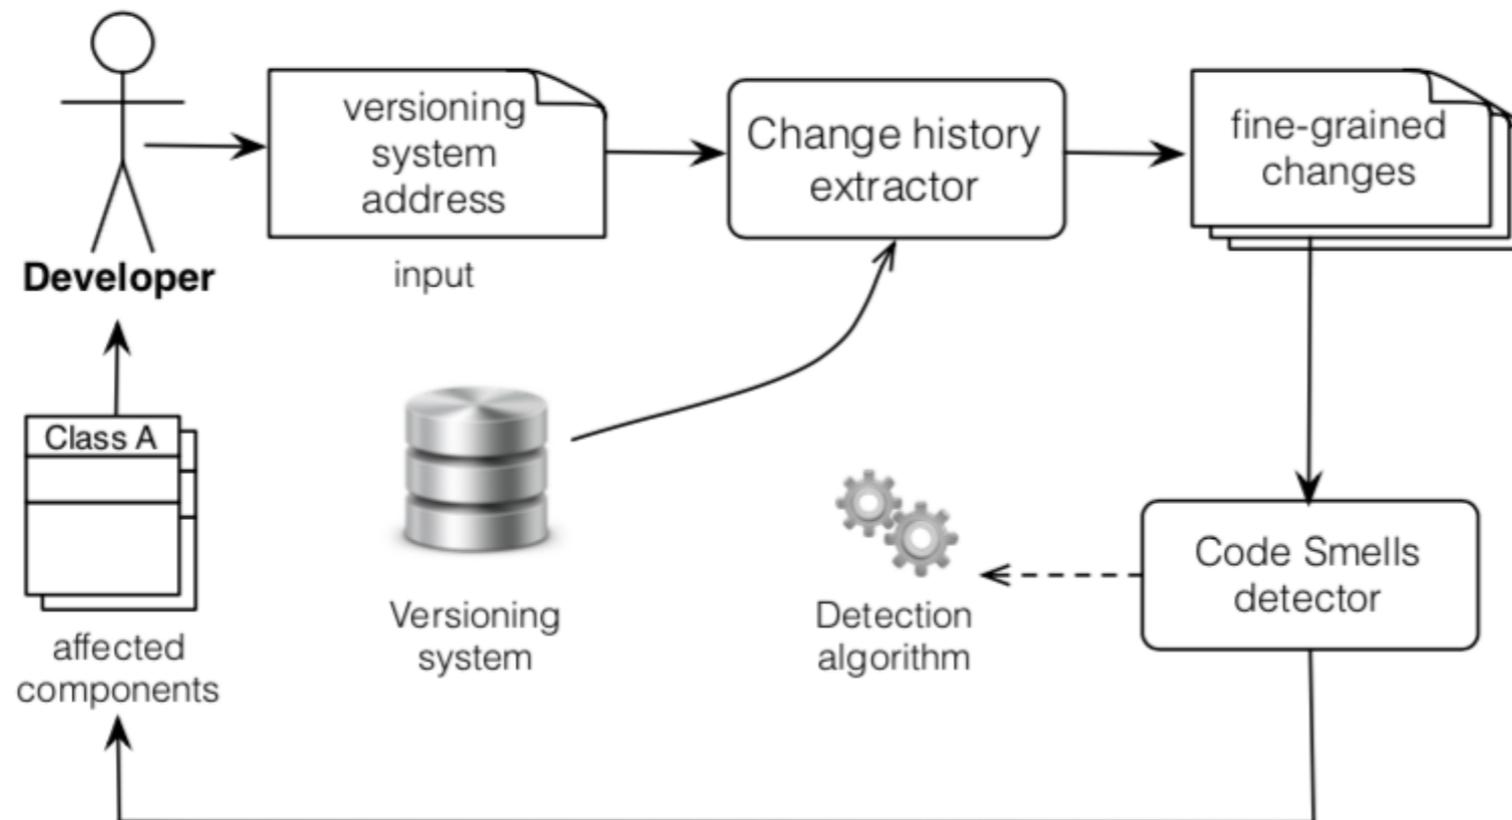


*Lanza and Marinescu (2007)*

- Rule Card
- Opportunités de refactorisation



- Rule Card
- Opportunités de refactorisation
- Information historique



*Palomba et al. (2013)*

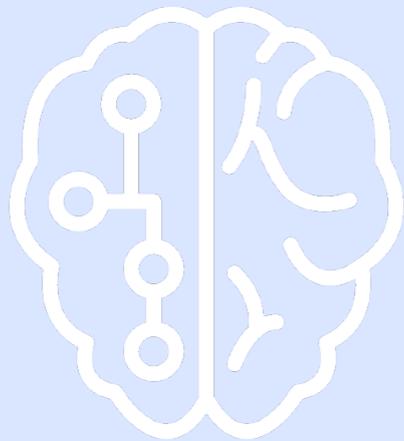
- Subjectivité des anti-patrons
- Métriques de détection définies arbitrairement
- Approches différentes, occurrences différentes
- Faible accord entre les différentes approches

Tirer profit de l'**apprentissage profond** pour détecter les anti-patterns à partir de plusieurs sources d'information  
(**Structurelles & Historiques**)

- Approche statistique
- Pas besoin de définir explicitement les règles de détection
- Capable de traiter des données complexes

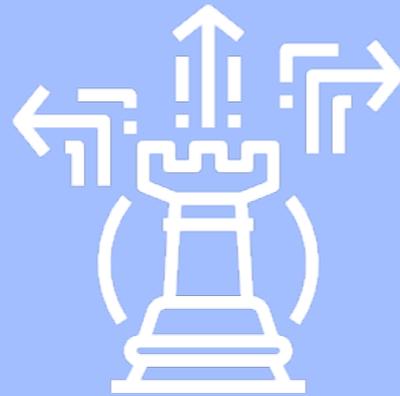
## Intelligence artificielle

Tout système  
accomplissant des  
tâches communément  
associées aux humains



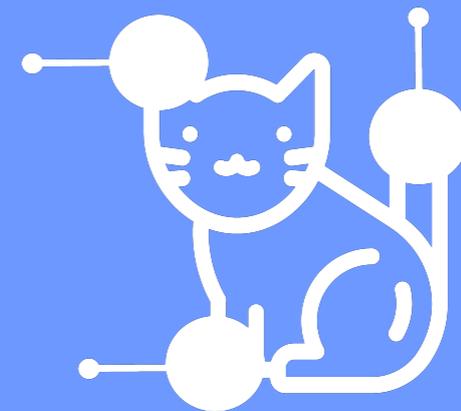
## Apprentissage automatique

Apprendre  
l'accomplissement  
d'une tâche sans que  
celle-ci soit définie  
explicitement



## Apprentissage profond

Apprendre les caractéristiques  
sous-jacentes des données en  
utilisant les réseaux de neurones

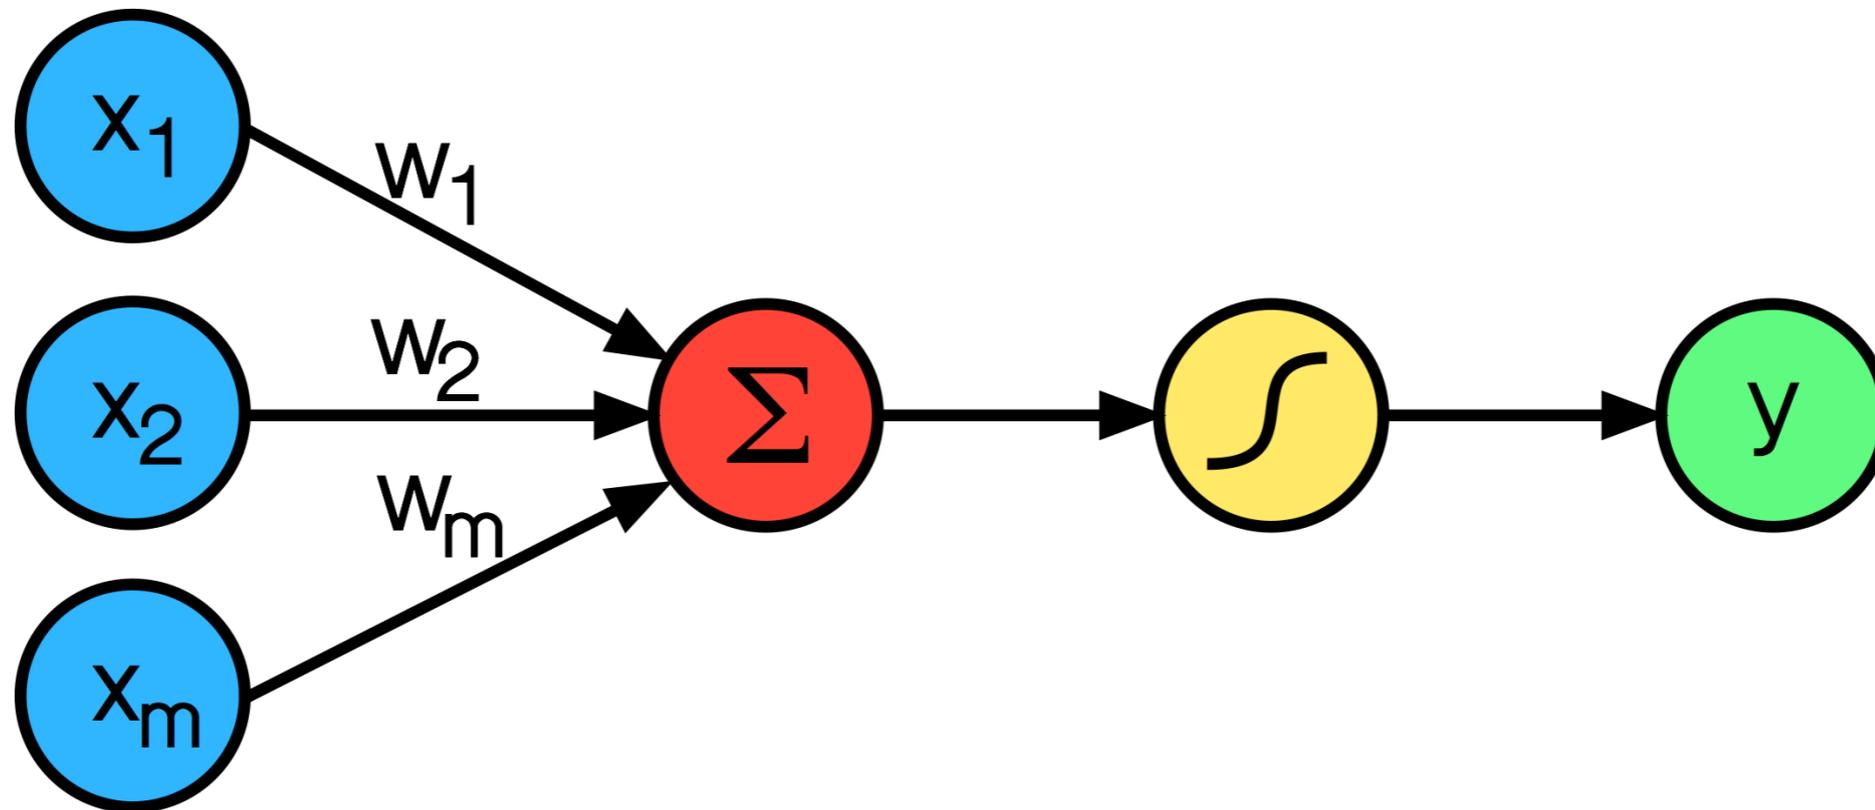


- Modèles probabilistes

$$\begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_m \end{bmatrix} \longrightarrow \begin{bmatrix} P(C_1 | X) \\ P(C_2 | X) \\ \vdots \\ P(C_k | X) \end{bmatrix}$$

- Composés d'entités élémentaires appelées **neurones**

## Le perceptron



Entrées

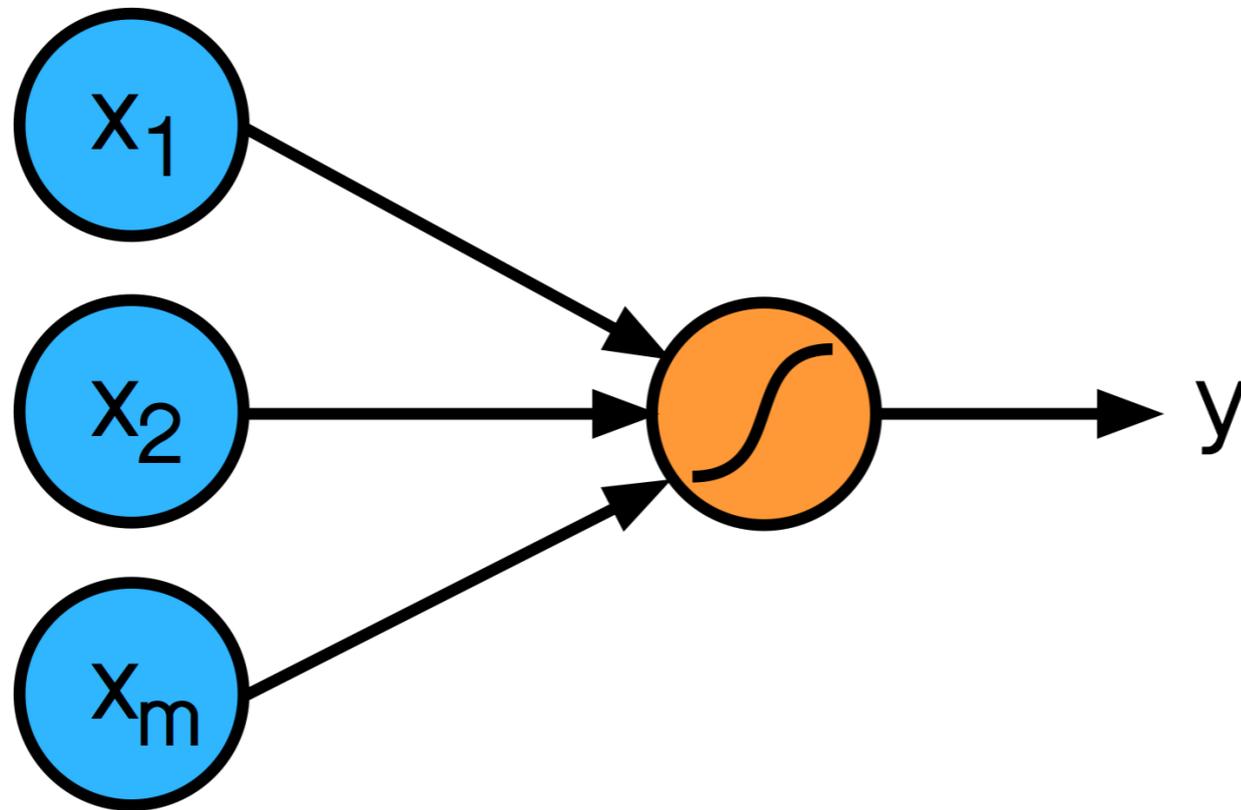
Poids

Somme

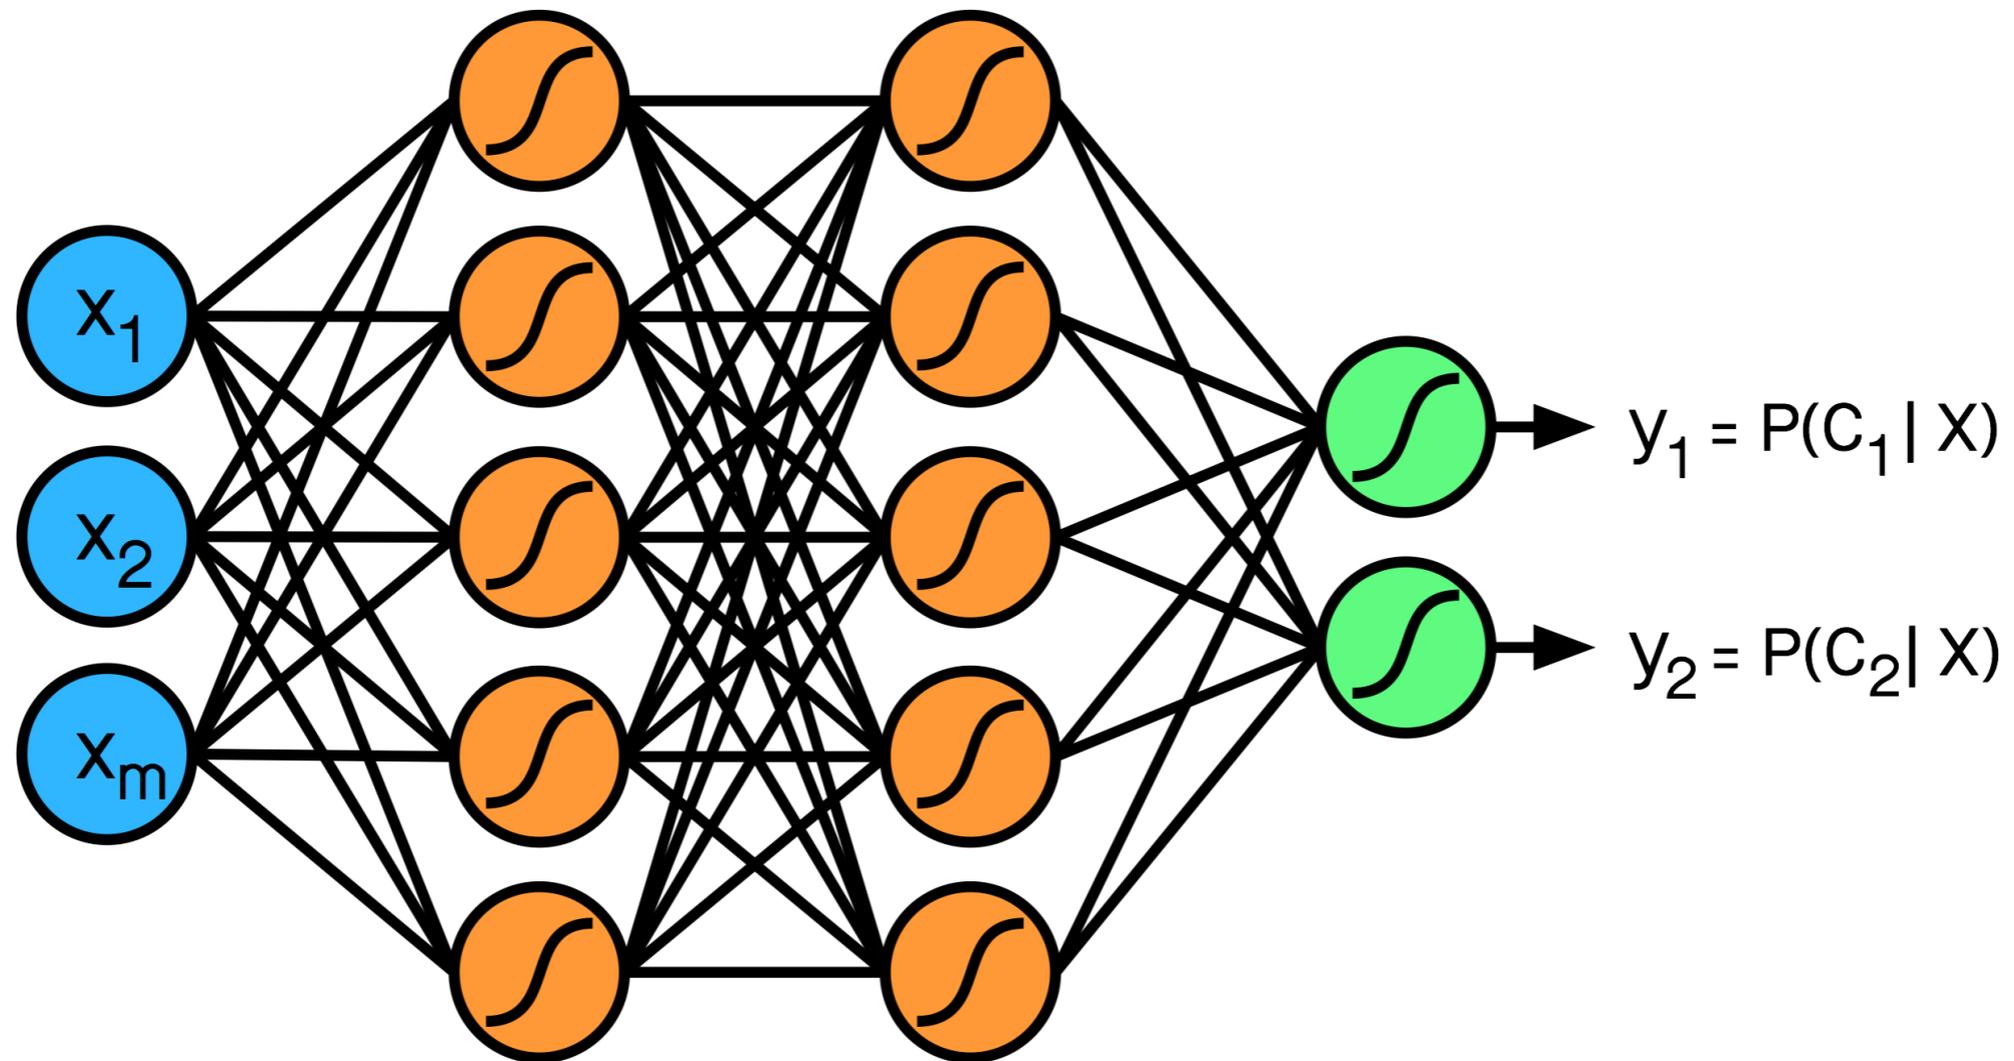
Activation

Sortie

## Le perceptron



## Perceptron multi-couches (MLP)

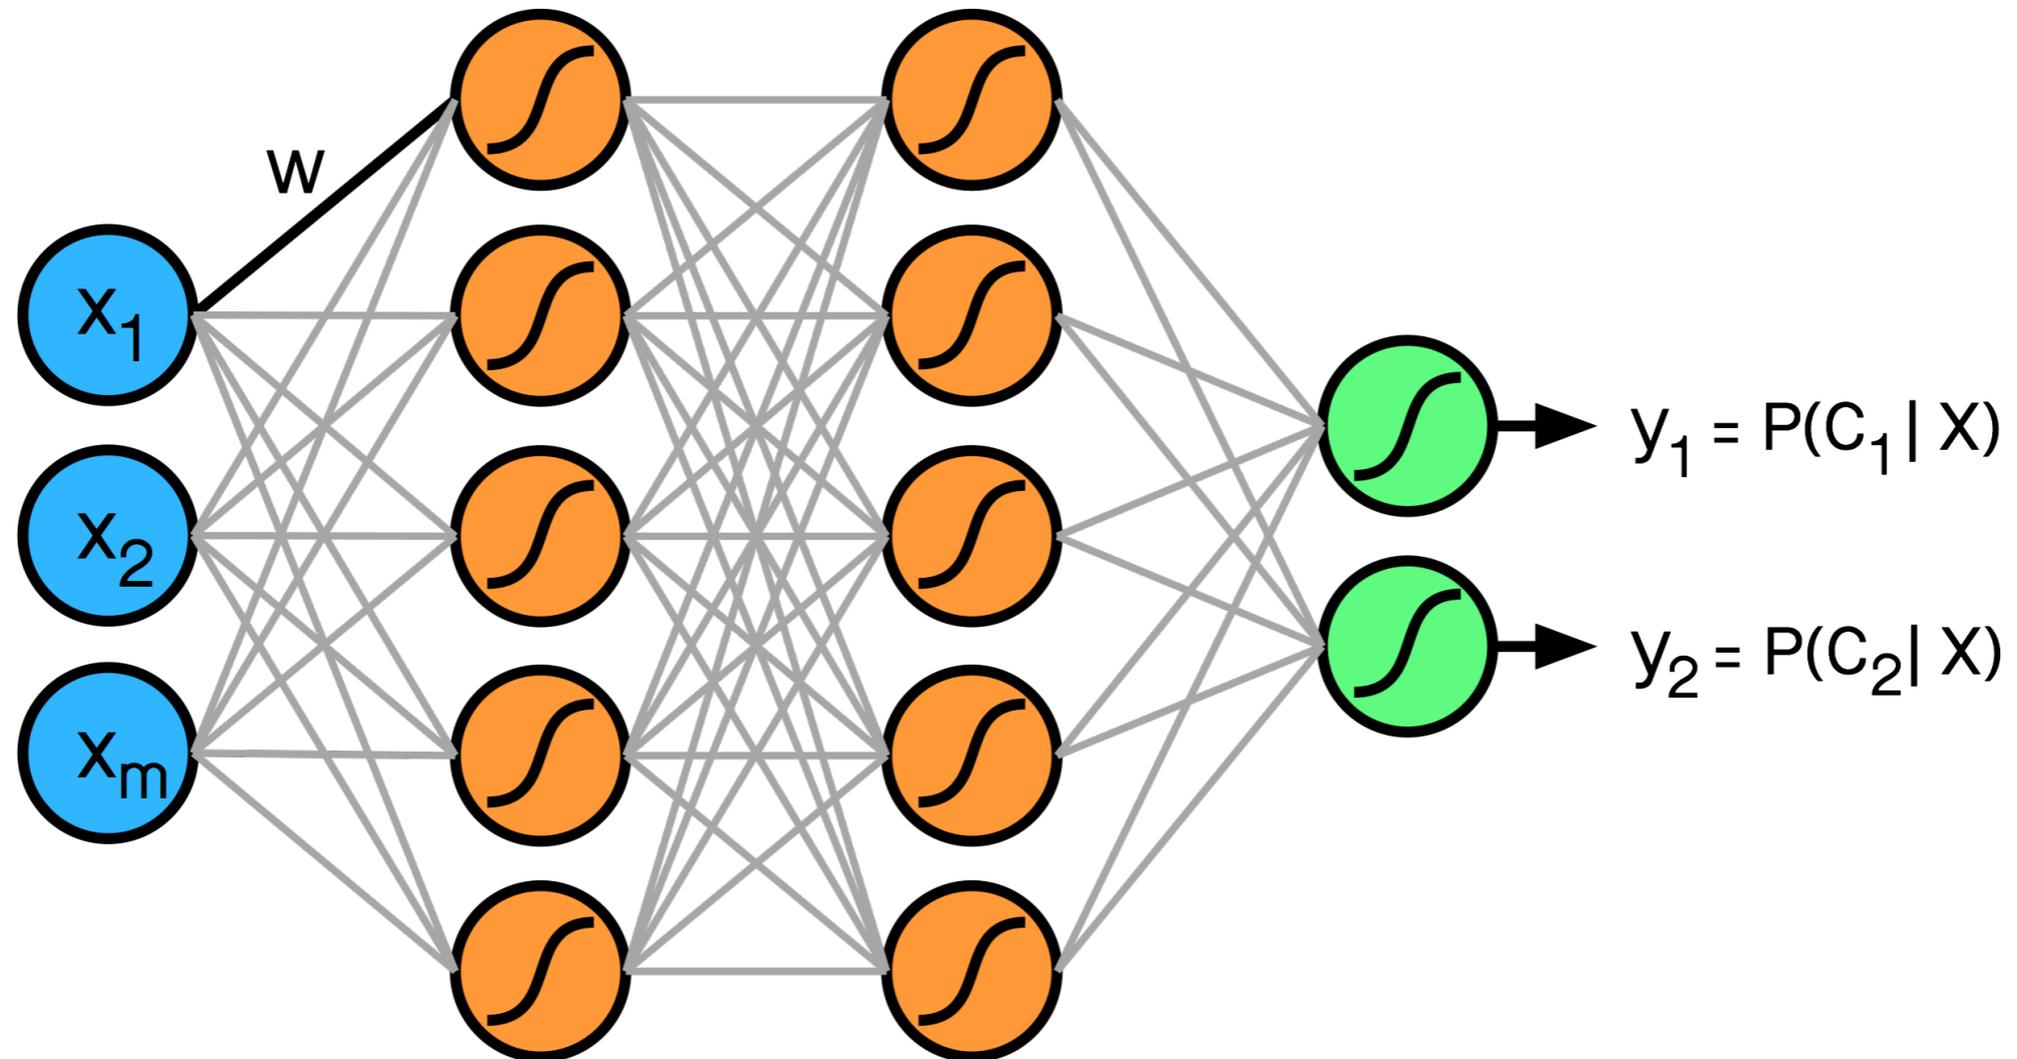


Couche  
d'entrée

Couches  
cachées

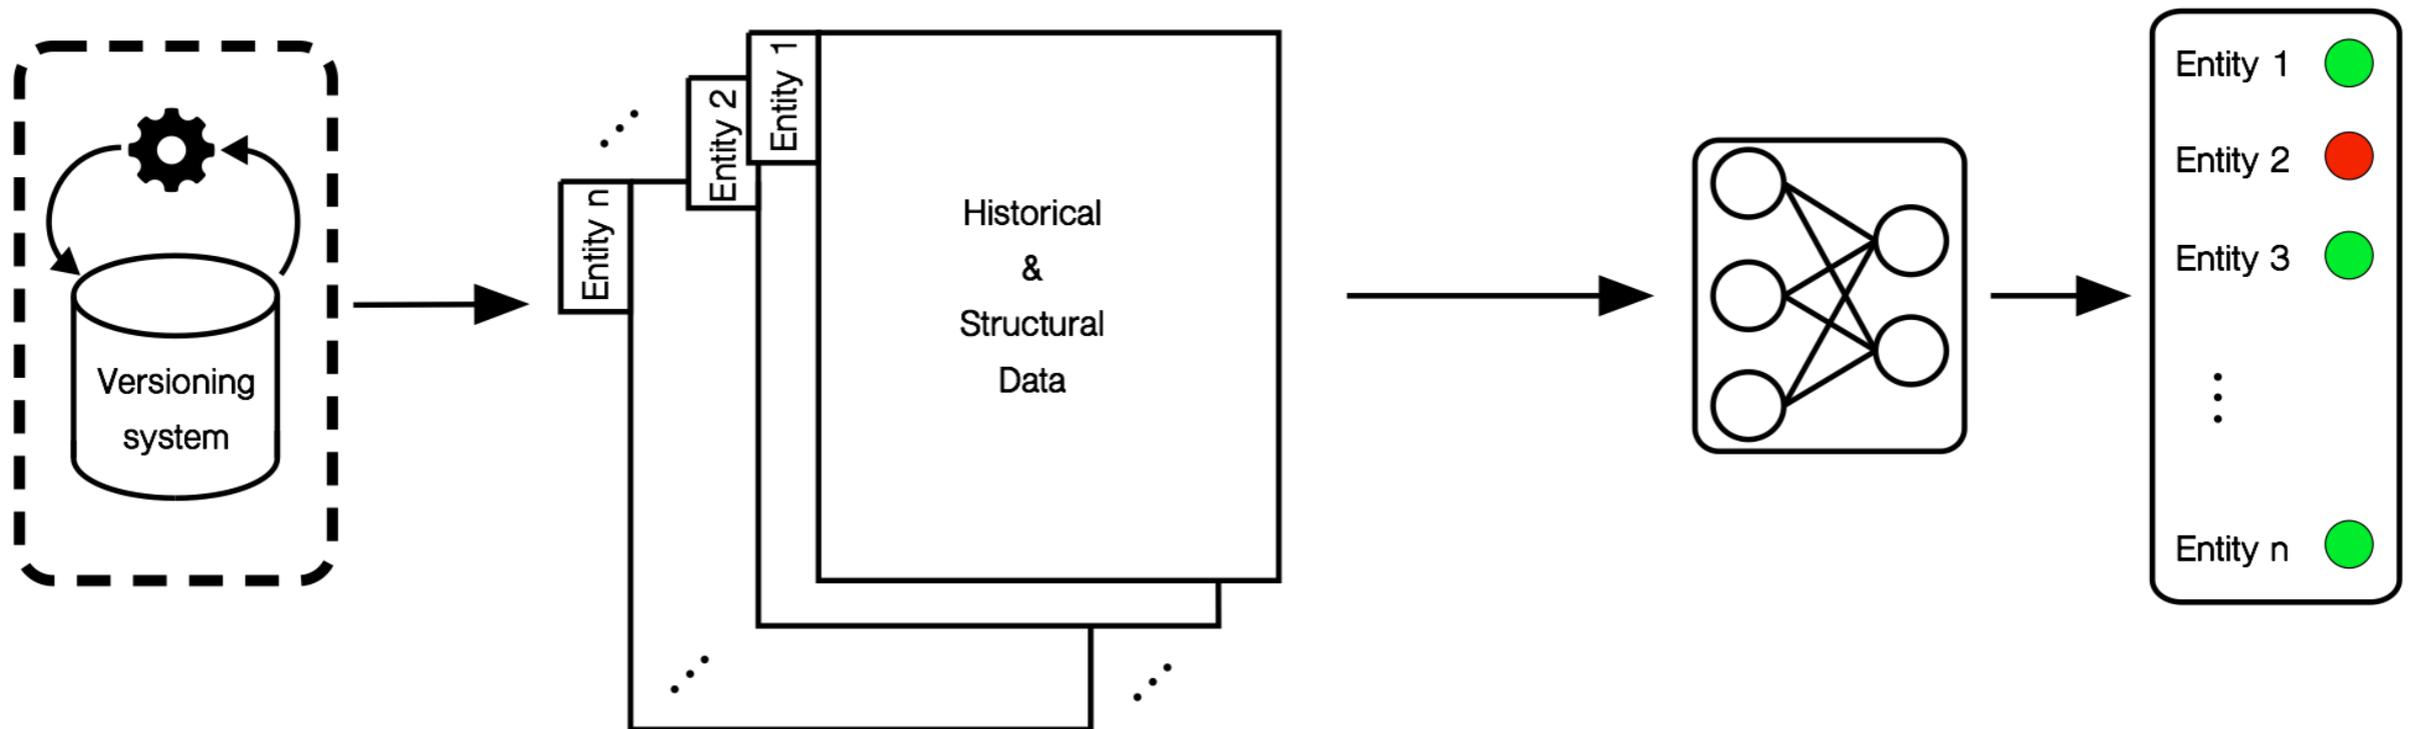
Couche  
de sortie

## Apprentissage



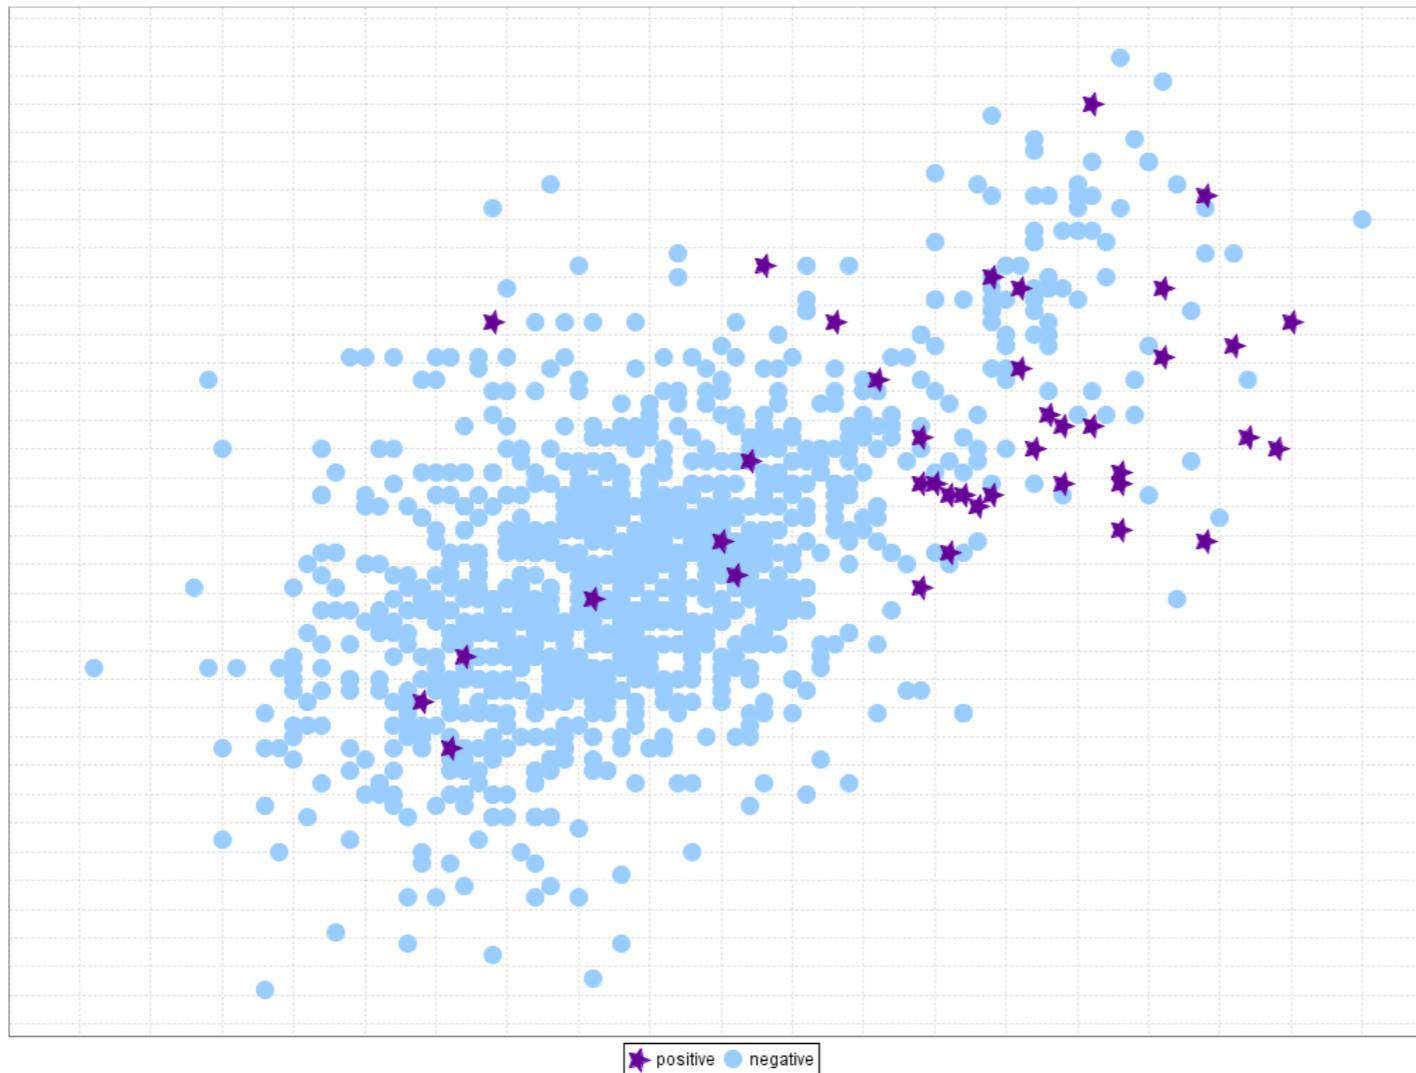
## **Utilisation des réseaux de neurones pour la détection d'anti-patterns à partir des données Structurelles et Historiques**

## Utilisation des réseaux de neurones pour la détection d'anti-patterns à partir des données Structurelles et Historiques



- Nécessaire pour entraîner et évaluer nos approches
- Occurrences de God Class et Feature Envy dans un ensemble de systèmes
- Construit différemment pour God Class et Feature Envy

Systemes	Taille	#God Class	#Feature Envy
Android Opt Telephony	192	11	18
Android Support	109	4	2
Apache Ant	694	7	25
Apache Tomcat	925	5	57
Apache Lucene	155	4	4
Apache Xerces	512	15	37
ArgoUML	1230	22	24
Jedit	423	5	22
<b>Total</b>	<b>4240</b>	<b>73</b>	<b>189</b>



● Précision

● Rappel

$$\mathbf{F\text{-mesure}} = 2x(PxR)/(P+R)$$

- Plusieurs approches de détection existent, basées sur différentes techniques et-ou sources d'information
- Des approches différentes identifient des occurrences différentes

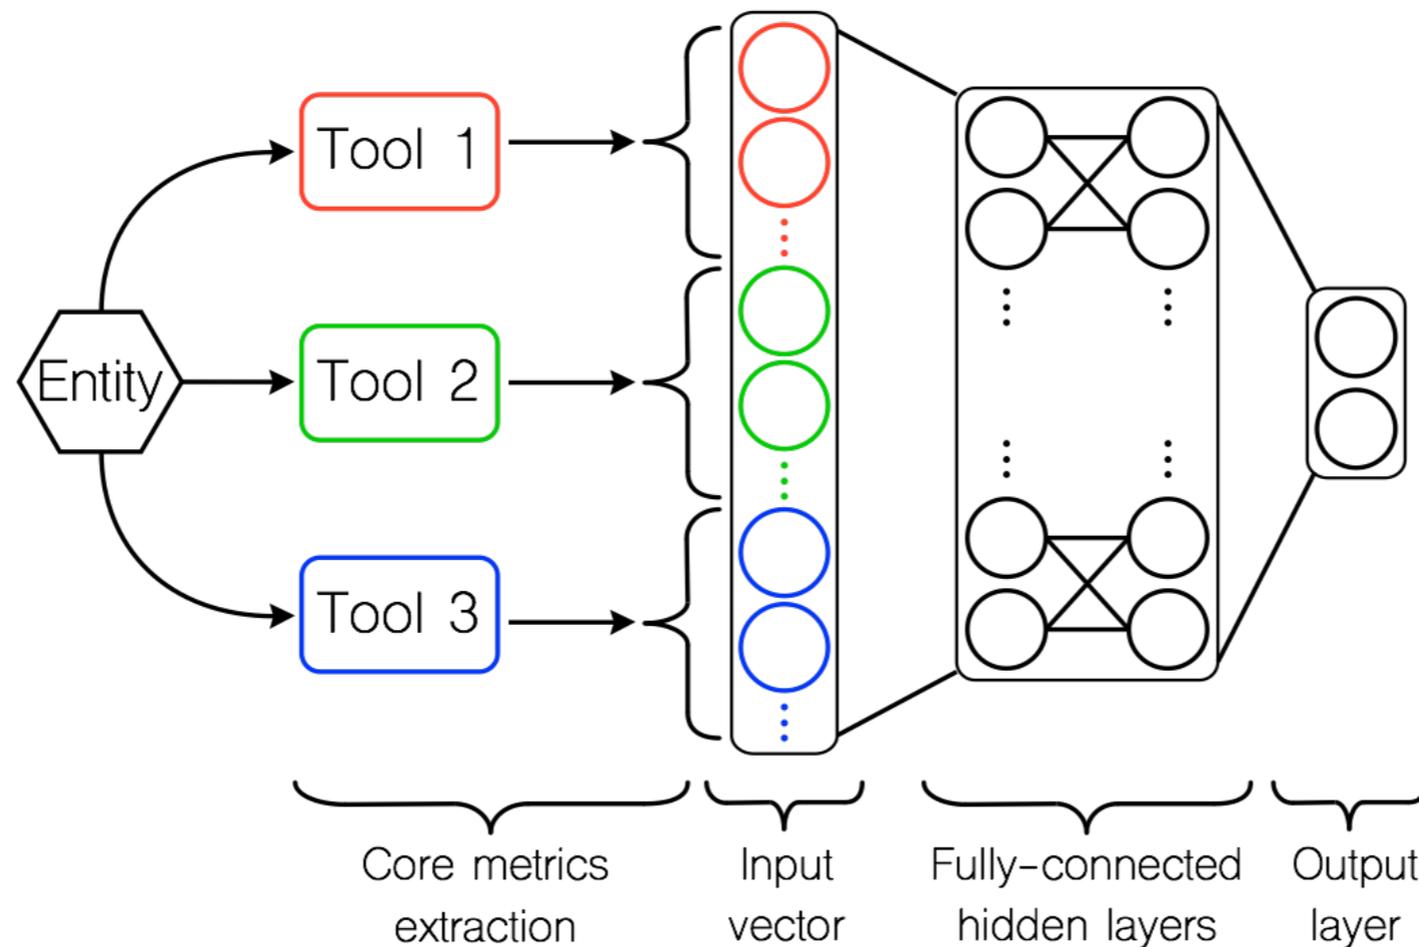
- Plusieurs approches de détection existent, basées sur différentes techniques et-ou sources d'information
- Des approches différentes identifient des occurrences différentes



Combiner ces différentes approches pour améliorer les performances de détection

Type d'approche	God Class	Feature Envy
Rule Card	DECOR	InCode
Refactoring	JDeodorant	JDeodorant
Historique	HIST	HIST

- Chaque approche à agréger est caractérisée par des **métriques**
- Utiliser ces métriques comme variables d'entrée à un réseau de neurones



- Méthode d'agrégation plus complète qu'un simple vote
- Architecture peu complexe donc simple à entraîner
- Générer automatiquement des instances d'apprentissage pour des architectures plus complexes

- Ensemble d'entraînement: **5** systèmes
- Ensemble de test: **3** systèmes

**RQ1:** SMAD améliore-t-elle les performances des approches agrégées?

**RQ2:** Comment SMAD se compare à d'autres méthodes d'agrégation?

**RQ3:** Les occurrences détectées par SMAD peuvent-elles être utilisées pour entraîner d'autres modèles?

## Moyenne des performances sur les trois systèmes

### God Class

Approche	Precision	Rappel	F-mesure
DECOR	28 %	33 %	25 %
JDeodorant	8 %	48 %	11 %
HIST	41 %	38 %	38 %
SMAD	<b>74 %</b>	<b>63 %</b>	<b>66 %</b>

### Feature Envy

Approche	Precision	Rappel	F-mesure
InCode	49 %	55 %	52 %
JDeodorant	59 %	47 %	50 %
HIST	4 %	4 %	4 %
SMAD	<b>74 %</b>	<b>67 %</b>	<b>70 %</b>

## Moyenne des performances sur les trois systèmes

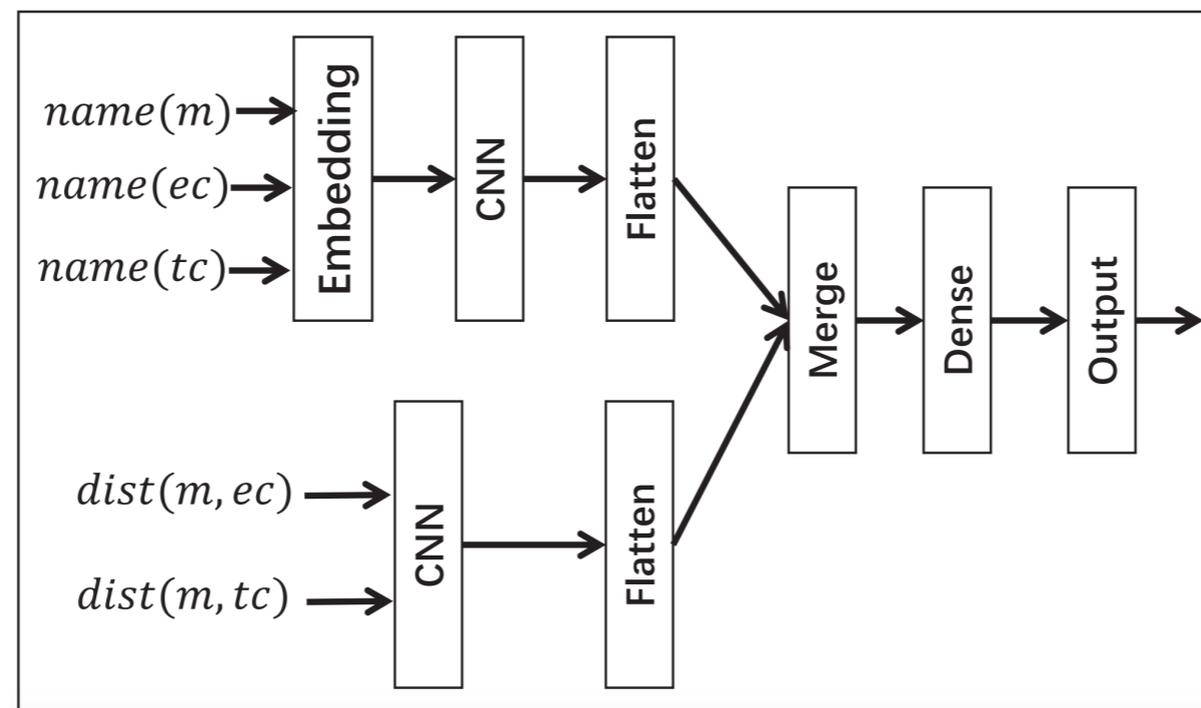
### God Class

Approche	Precision	Rappel	F-mesure
Vote k=1	15 %	<b>78 %</b>	22 %
Vote k=2	71 %	28 %	31 %
Vote k=3	22 %	13 %	16 %
SMAD	<b>74 %</b>	63 %	<b>66 %</b>

### Feature Envy

Approche	Precision	Rappel	F-mesure
Vote k=1	28 %	<b>100 %</b>	43 %
Vote k=2	52 %	7 %	12 %
Vote k=3	0 %	0 %	0 %
SMAD	<b>74 %</b>	67 %	<b>70 %</b>

- Seulement pour Feature Envy
- Architecture sélectionnée: *Liu et al. (2018)*



- Entraîné sur 11 systèmes

## Moyenne des performances sur les trois systèmes

Approche	Precision	Rappel	F-mesure
LIU_INJ	1 %	<b>94 %</b>	3 %
LIU_SMAD	<b>22 %</b>	13 %	<b>16 %</b>

- « Vrai » approche d'apprentissage profond
- Travaille avec des données complexes
- Traite l'information structurelle et historique simultanément

- « Vrai » approche d'apprentissage profond
- Travaille avec des données complexes
- Traite l'information structurelle et historique simultanément



Analyser l'évolution des métriques au cours du développement du logiciel

## 3 commits

NMD NAD LOC

```
1 public class Dog {
2     private String name;
3     private int age;
4
5
6     //Constructor
7     public Dog(String name, int age) {
8         this.name = name;
9         this.age = age;
10    }
11
12
13    //Accessors
14    public int getAge() {
15        return this.age;
16    }
17
18    public setAge(int newAge) {
19        this.age = newAge;
20    }
21
22    public String getName() {
23        return this.name;
24    }
25
26
27    //Features
28    public void bark() {
29        System.out.println("WOOF WOOF!")
30    }
31 }
```

```
1 public class Dog {
2     private String name;
3     private int age;
4
5
6     //Constructor
7     public Dog(String name, int age) {
8         this.name = name;
9         this.age = age;
10    }
11
12
13    //Accessors
14    public int getAge() {
15        return this.age;
16    }
17
18    public setAge(int newAge) {
19        this.age = newAge;
20    }
21
22    public String getName() {
23        return this.name;
24    }
25
26
27    //Features
28    public void bark() {
29        System.out.println("WOOF WOOF!")
30    }
31 }
```

	NMD	NAD	LOC
Commit 1			5

```
1 public class Dog {
2     private String name;
3     private int age;
4
5
6     //Constructor
7     public Dog(String name, int age) {
8         this.name = name;
9         this.age = age;
10    }
11
12
13    //Accessors
14    public int getAge() {
15        return this.age;
16    }
17
18    public void setAge(int newAge) {
19        this.age = newAge;
20    }
21
22    public String getName() {
23        return this.name;
24    }
25
26
27    //Features
28    public void bark() {
29        System.out.println("WOOF WOOF!")
30    }
31 }
```

	NMD	NAD	LOC
Commit 1	5	2	

```
1  public class Dog {
2      private String name;
3      private int age;
4
5
6      //Constructor
7      public Dog(String name, int age) {
8          this.name = name;
9          this.age = age;
10     }
11
12
13     //Accessors
14     public int getAge() {
15         return this.age;
16     }
17
18     public void setAge(int newAge) {
19         this.age = newAge;
20     }
21
22     public String getName() {
23         return this.name;
24     }
25
26
27     //Features
28     public void bark() {
29         System.out.println("WOOF WOOF!")
30     }
31 }
```

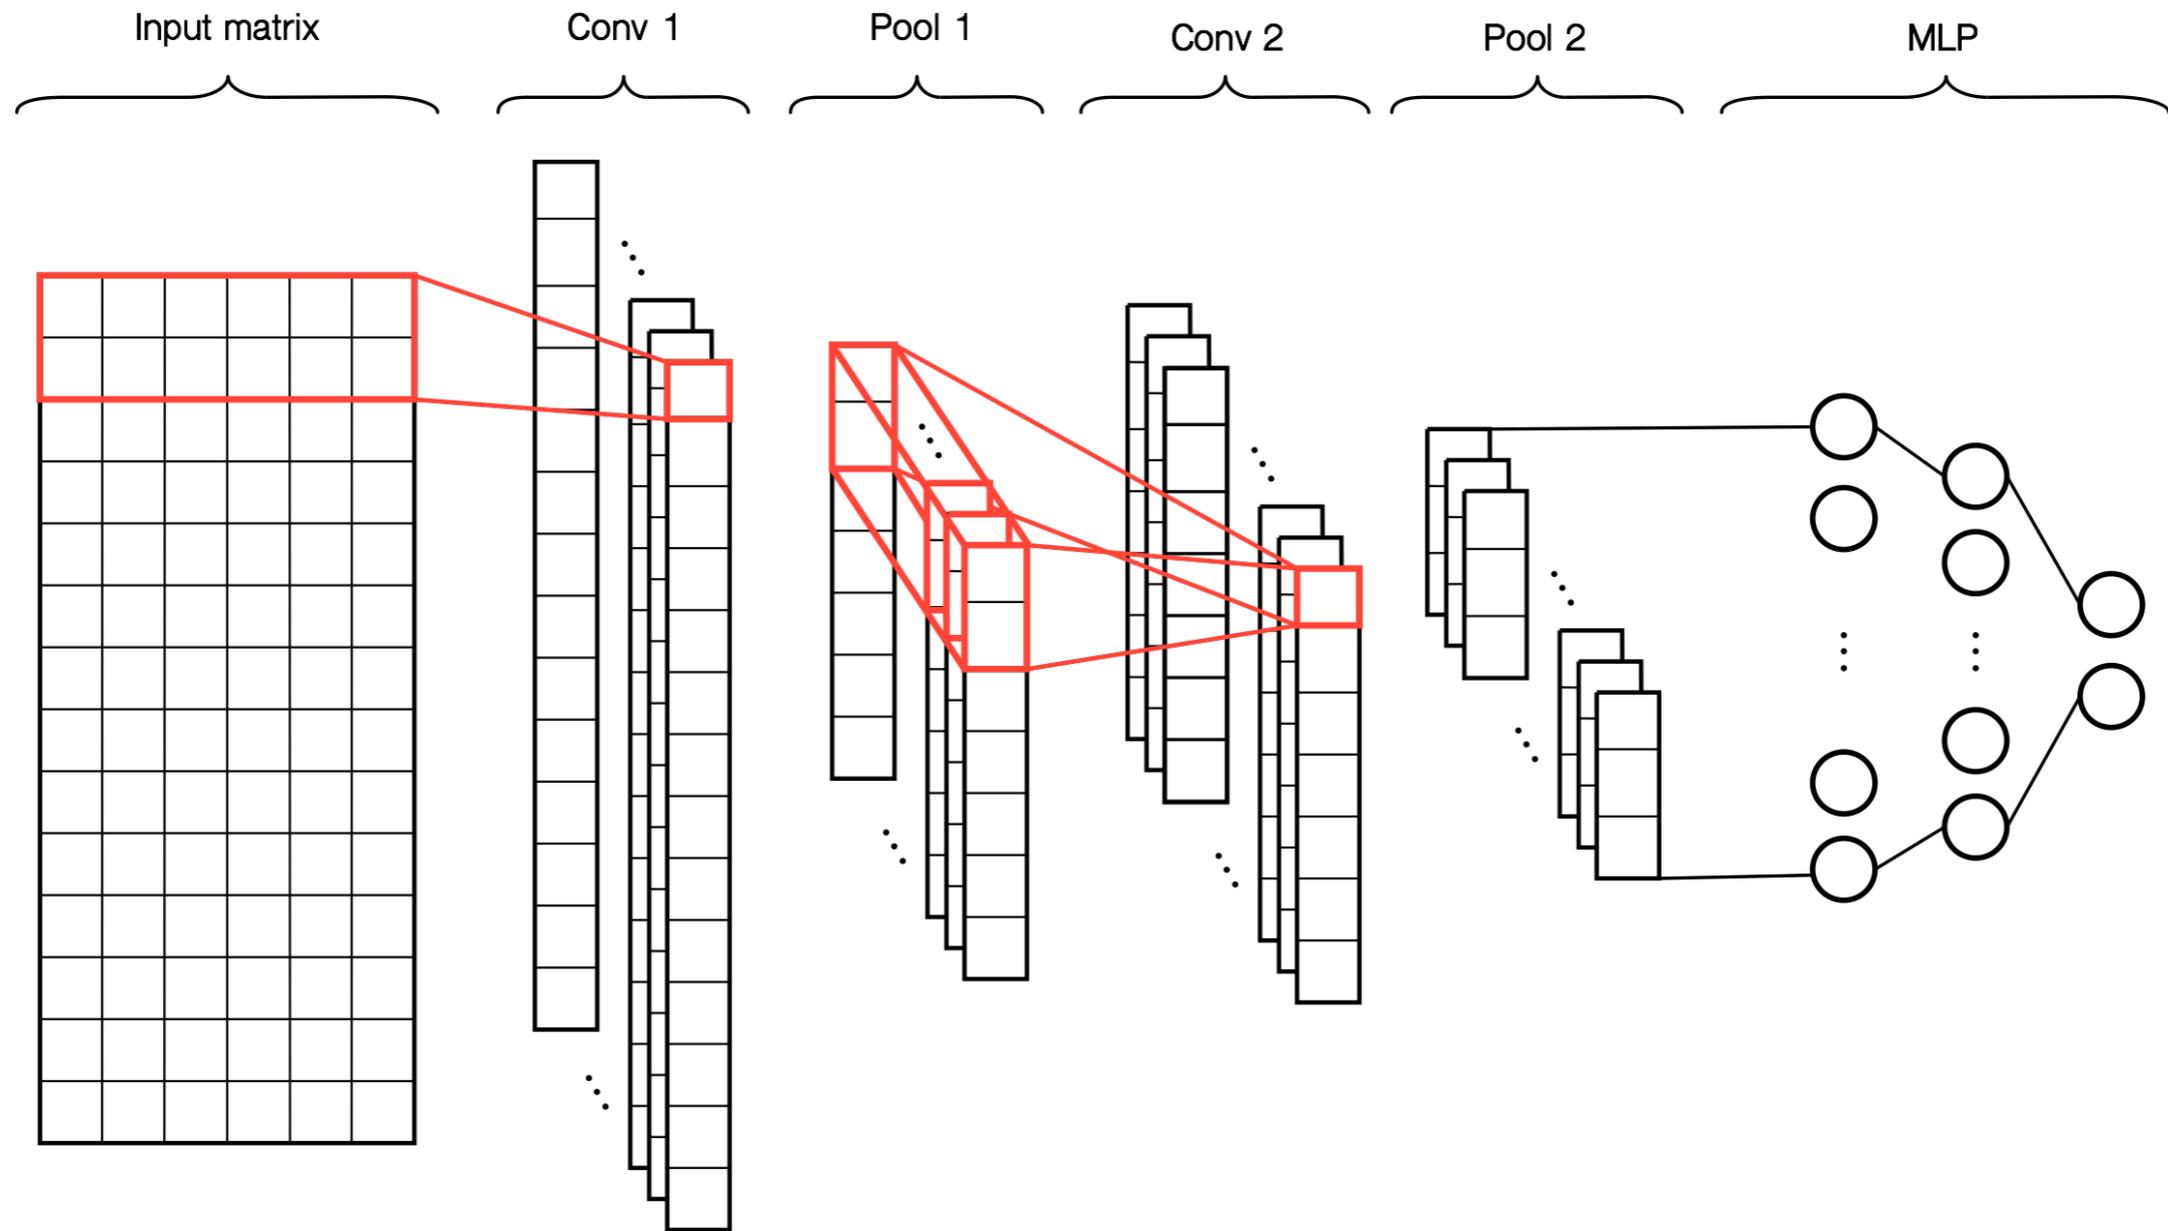
	NMD	NAD	LOC
Commit 1	5	2	31

```
1 public class Dog {
2     private String name;
3     private int age;
4
5
6     //Constructor
7     public Dog(String name, int age) {
8         this.name = name;
9         this.age = age;
10    }
11
12
13    //Accesors
14    public int getAge() {
15        return this.age;
16    }
17
18    public setAge(int newAge) {
19        this.age = newAge;
20    }
21
22    public String getName() {
23        return this.name;
24    }
25 }
```

	NMD	NAD	LOC
Commit 1	5	2	31
Commit 2	4	2	25

```
1 public class Dog {
2     private String name;
3
4
5     //Constructor
6     public Dog(String name) {
7         this.name = name;
8     }
9
10
11     //Accessors
12     public String getName() {
13         return this.name;
14     }
15 }
```

	NMD	NAD	LOC
Commit 1	5	2	31
Commit 2	4	2	25
Commit 3	2	1	15

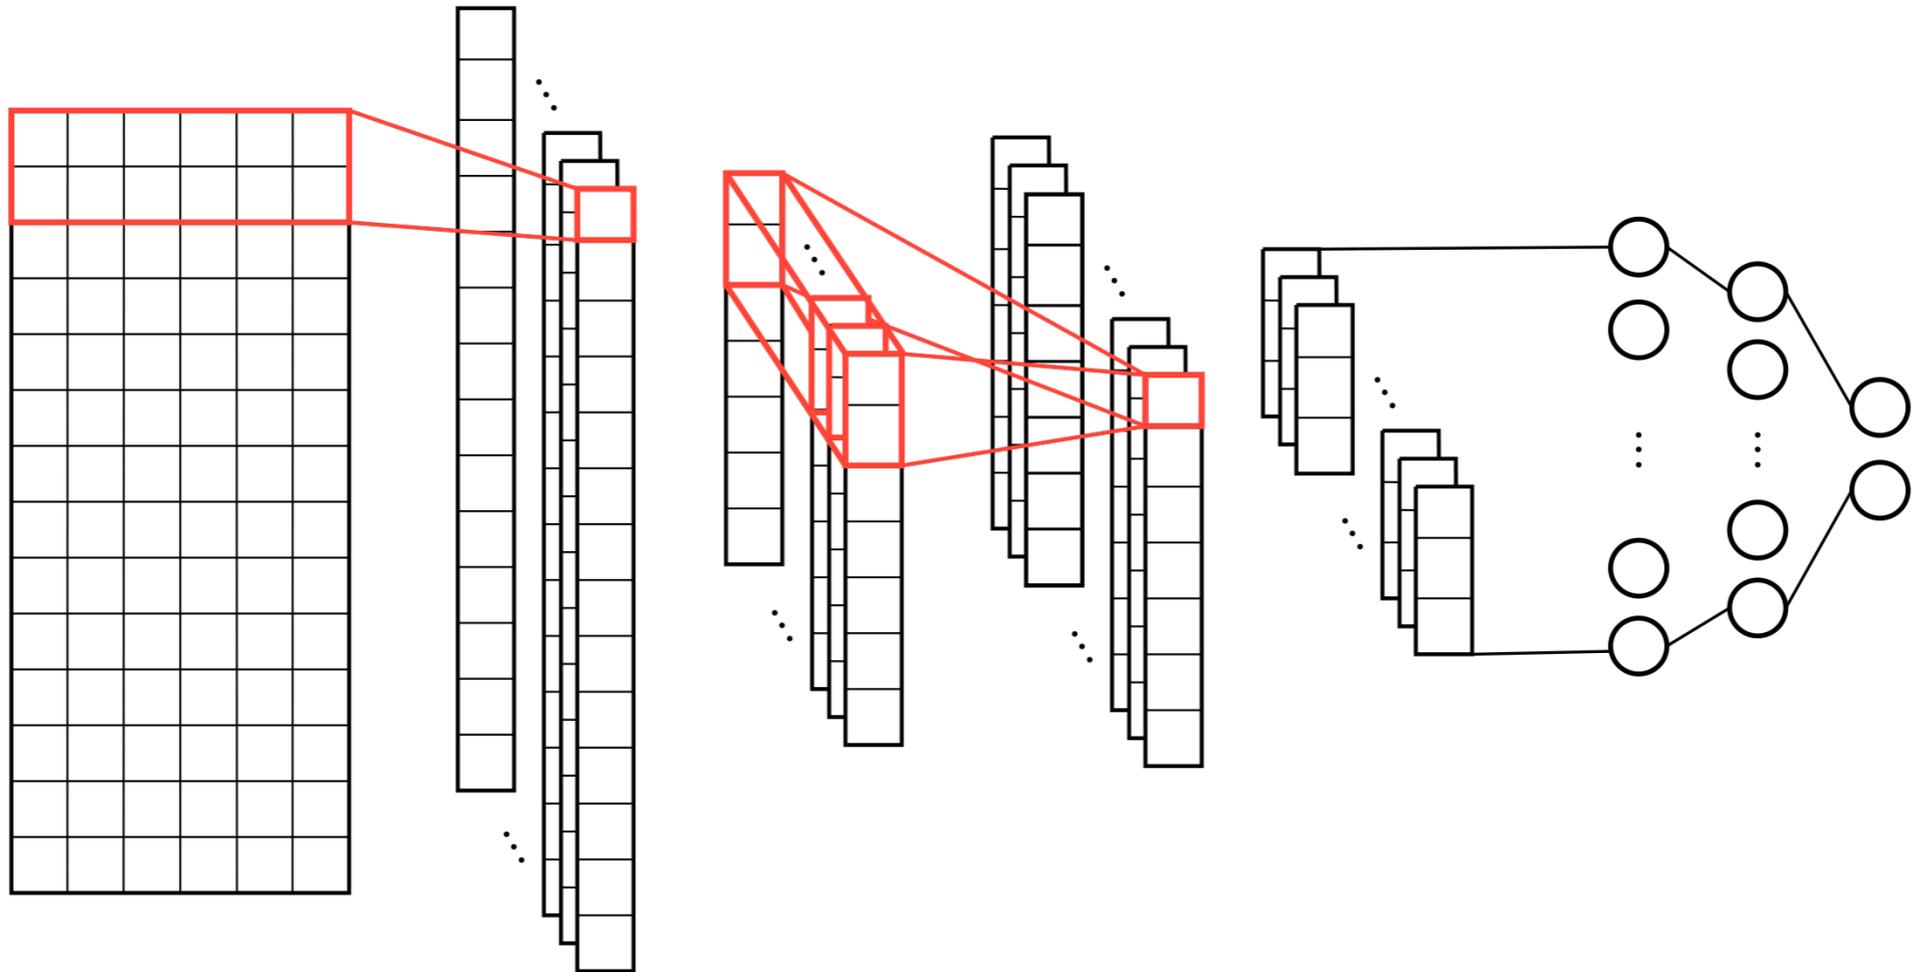


- Implémentation pour **God Class**
- Ensemble d'entraînement: **5 + 11** systèmes
- Ensemble de test: **3** systèmes

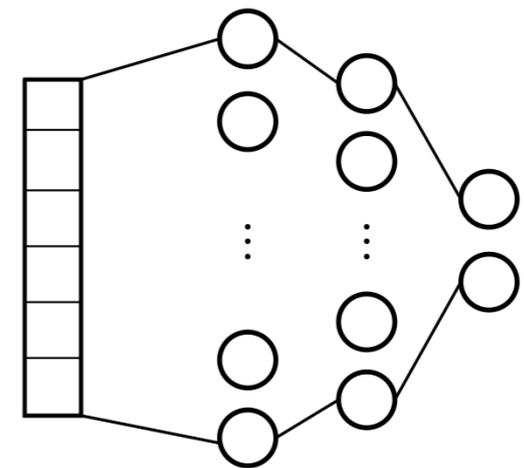
**RQ1:** L'historique des métriques améliore-t-il les performances?

**RQ2:** Comment CAME se compare aux approches de détection existantes?

CAME



MLP



## Moyenne des performances sur les trois systèmes

### God Class

Approche	Precision	Rappel	F-mesure
DECOR	28 %	33 %	25 %
JDeodorant	8 %	48 %	11 %
HIST	41 %	38 %	38 %
MLP	<b>73 %</b>	63 %	63 %
CAME	72 %	<b>78 %</b>	<b>72 %</b>

- Importance de la détection des anti-patterns dans les systèmes logiciels
- Limites des approches existantes
- Oracle
- Deux approches de détection basées sur le l'apprentissage profond reposant sur les données structurelles et historiques
  - SMAD:**
    - Agréger des outils de détection existants
    - Générer des instances d'apprentissage
  - CAME:**
    - Analyser l'évolution des métriques logicielles

## SMAD

- Expérimenter d'autres architectures
- Comparer avec d'autres méthodes d'agrégation

## CAME

- Étendre notre approche à Feature Envy
- Tirer profit des techniques de visualisation pour identifier les caractéristiques profondes et les causes premières des anti-patterns

- W. J. Brown, R. C. Malveau, W. H. Brown, H. W. McCormick III, et T. J. Mowbray, *Anti Patterns: Refactoring Software, Architectures, and Projects in Crisis*, 1st éd. John Wiley and Sons, March 1998.
- M. Fowler, *Refactoring: Improving the Design of Existing Code*. Boston, MA, USA: Addison-Wesley, 1999.
- F. Palomba, G. Bavota, M. D. Penta, R. Oliveto, A. D. Lucia, et D. Poshyvanyk, “*Detecting bad smells in source code using change history information.*” dans ASE, 2013, pp. 268–278.
- N. Moha, Y. Guéhéneuc, D. Laurence, et L. M. Anne-Francoise, “*Decor: A method for the specification and detection of code and design smells*”, IEEE Transactions on Software Engineering (TSE), vol. 36, no. 1, pp. 20–36, 2010.
- M. Fokaefs, N. Tsantalis, E. Stroulia, et A. Chatzigeorgiou, “*Ideodorant: identification and application of extract class refactorings*”, dans Software Engineering (ICSE), 2011 33rd International Conference on. IEEE, 2011, pp. 1037–1039.
- M. Lanza et R. Marinescu, *Object-oriented metrics in practice: using software metrics to characterize, evaluate, and improve the design of object-oriented systems*. Springer Science & Business Media, 2007.