

Elaboration d'un contrôleur prédictif auto-adaptatif basé sur des réseaux de neurones artificiels :

Houssam MOUMOUH

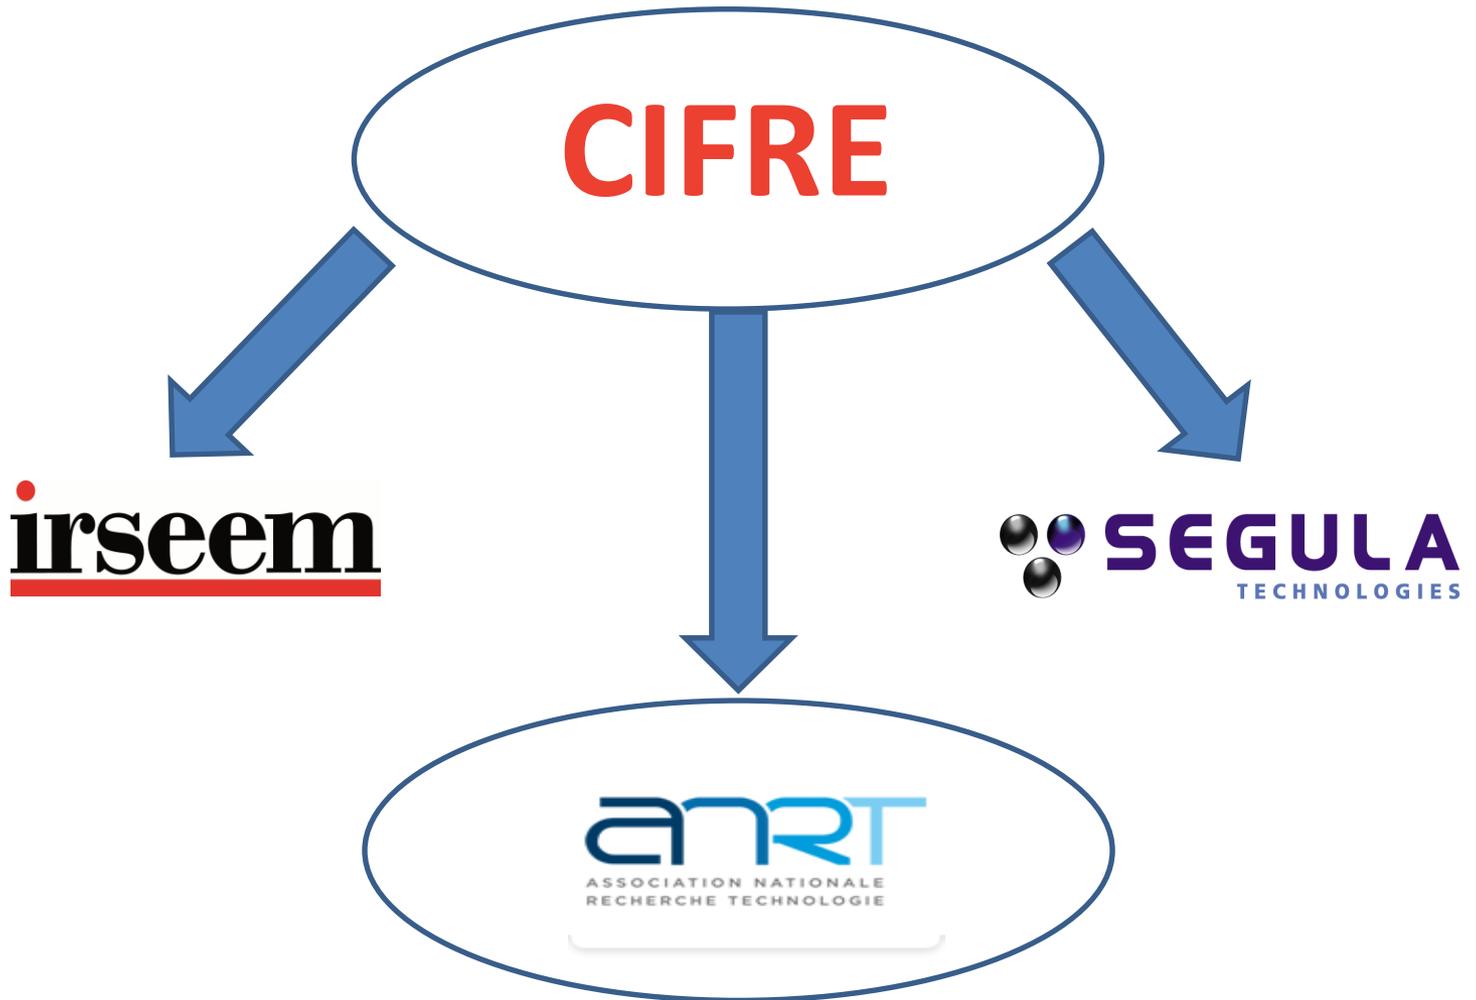
Directeur de thèse : **Nicolas LANGLOIS**

Responsable entreprise : **Madjid HADDAD**

13/06/2019

- **Contexte & objectifs**
- **Etat de l'art sur les méthodes de réglage de la MPC et sur les méthodes d'apprentissage des RNA**
- **Méthode de réglage proposée**
- **Application de l'algorithme proposé sur des systèmes issus de la littérature**
- **Travaux en cours et à venir**

- Contexte :



- Description du groupe :



- Groupe d'ingénierie présent mondialement au service de la compétitivité des grands secteurs:

- Automobile,
- Aéronautique,
- Energie,
- Ferroviaire,
- ...

 11 000
COLLABORATEURS

 28
P A Y S

 140
IMPLANTATIONS

PLUS DE
300
C L I E N T S
I N D U S T R I E L S



- Description du groupe :



SEGULA Technologies place l'innovation au cœur de sa stratégie. Les nombreux travaux de Recherche & Innovation du Groupe s'articulent autour des problématiques industrielles d'avenir de ses clients :

E SENSE



EF01



Hagora



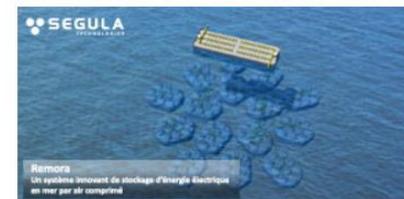
Green deliriver



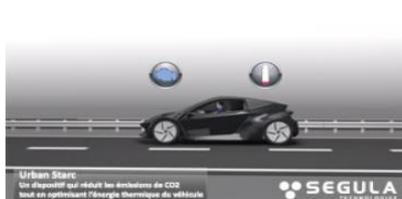
Eolienne offshore autonome



Remora



Urban Starc



Drone industriel autonome - Atlas



- Problématique :

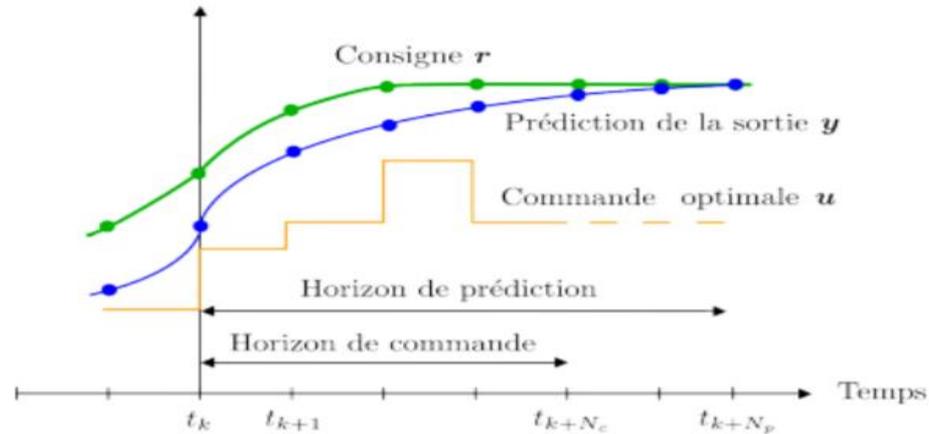


FIGURE 1.1 – Principe de la commande prédictive [Cazy, 2016]

$$J = \sum_{j=0}^{Np} \varepsilon(k+j)^2 + \lambda \sum_{j=0}^{Nc} u(k+j)^2$$

Np : Horizon de prédiction

Nc : Horizon de commande

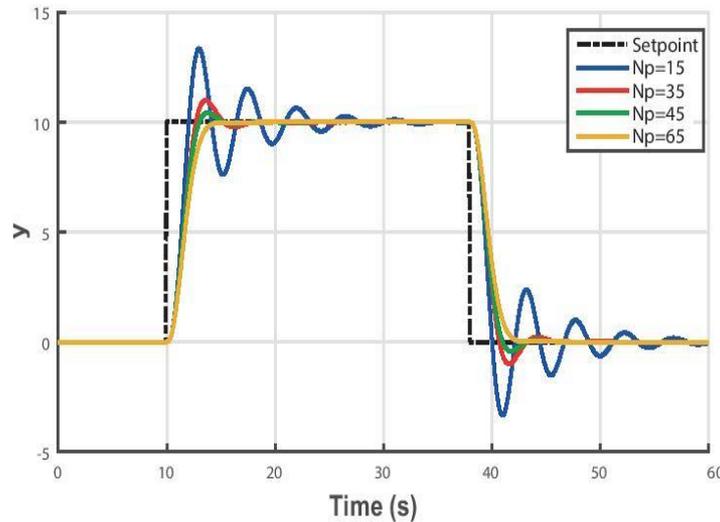
λ : Facteur de pondération

Influence des paramètres de réglage de la MPC sur les performances du système :

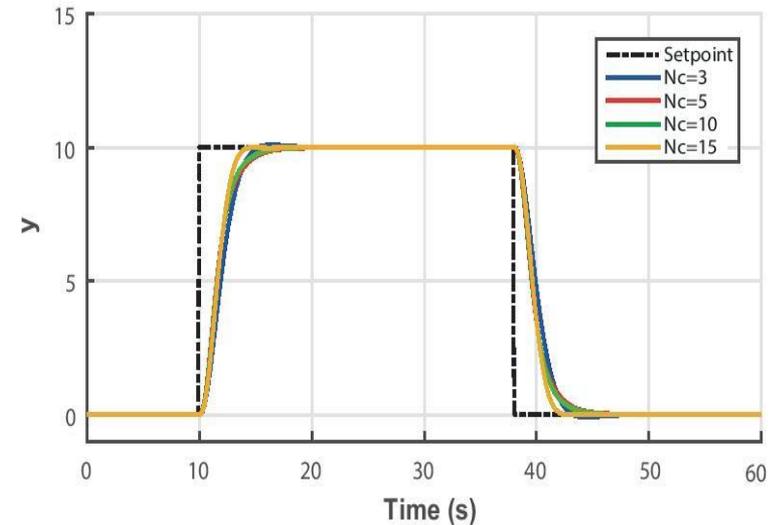
N_c : Horizon de commande

N_p : Horizon de prédiction

λ : facteur de pondération



Influence de l'horizon de prédiction
[Benkhoud and bouallègue, 2016]



Influence de l'horizon de commande
[Benkhoud and bouallègue, 2016]

Travaux liant la MPC aux RNA :

Contrôle d'un système pneumatique basé sur un modèle ARMAX optimisé à l'aide d'un RNA

- *Qiang Song, Fang Liu, Raymond D. Findlay (2006)* (International Conference on Computational Intelligence for Modelling Control and Automation). IEEE

Contrôle d'un système de combustion modélisé à l'aide d'un RNA

- *Ning Du, XiuHong Long, Li Zhao (2014)*. (Chinese Control and Decision Conference). IEEE

Utilisation des RNA pour une approximation stochastique de la MPC

- *Na Dong, Derong Liu and Zengqiang Chen (2011)*. (International Conference on Modelling, Identification and Control, Shanghai, China,). IEEE

- Etat de l'art sur les approches de réglages :

1/ Approches analytiques :

- Optimisation des paramètres de la DMC selon une approche exacte [Shridhar et Cooper, 1997b],
- Optimisation des paramètres de la MPC [Turki 2017],

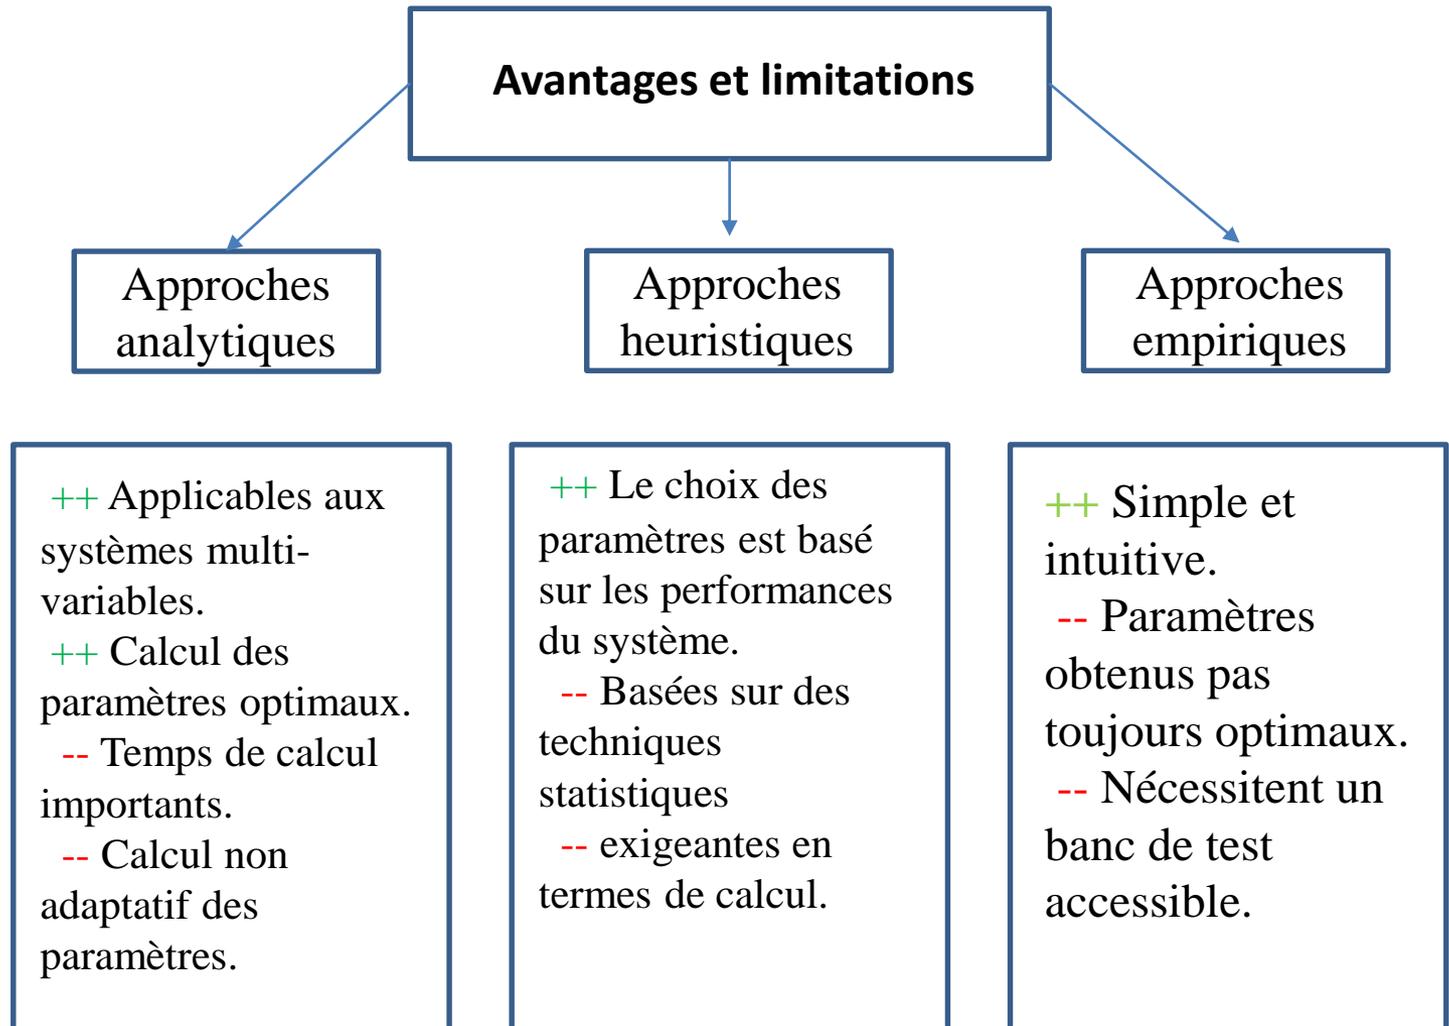
2/ Approches heuristiques :

- Les approches à base du logique floue [Mamboundou 2011],
- Les approches à base d'algorithmes génétiques [Haber et al., 2004]
- Les approches à partir d'équations de sensibilité [Al-Ghazzawi et al., 2001a]

3/ Approches empiriques :

- Réglage des paramètres en se basant sur les performances de stabilité en boucle ouverte du système [Dumur, 1996]
- Réglage des paramètres en reformulant la fonction coût de la MPC comme celle d'un régulateur linéaire quadratique [Wang, 2009]

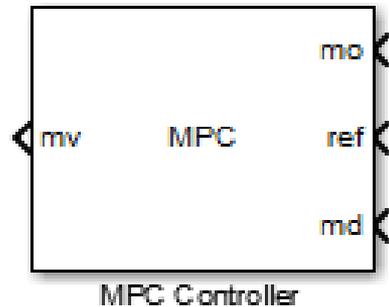
Avantages et limites des différentes approches :



- Programmation de la MPC :

Limitation des outils existants :

Toolbox MPC Matlab :

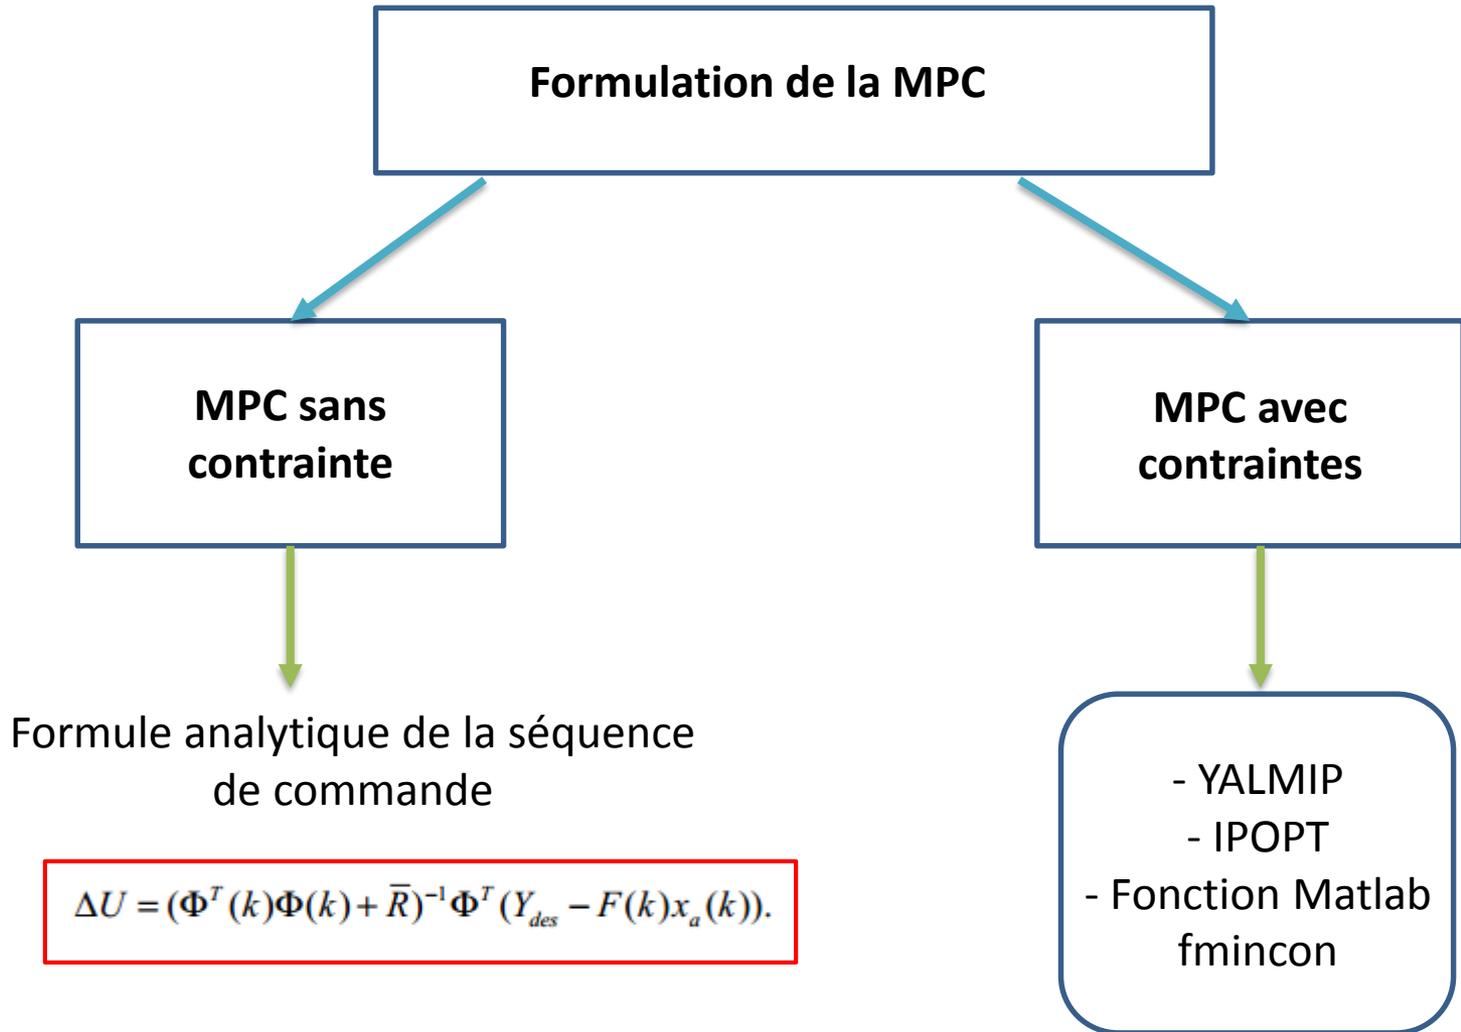


Nc, Np et λ constants

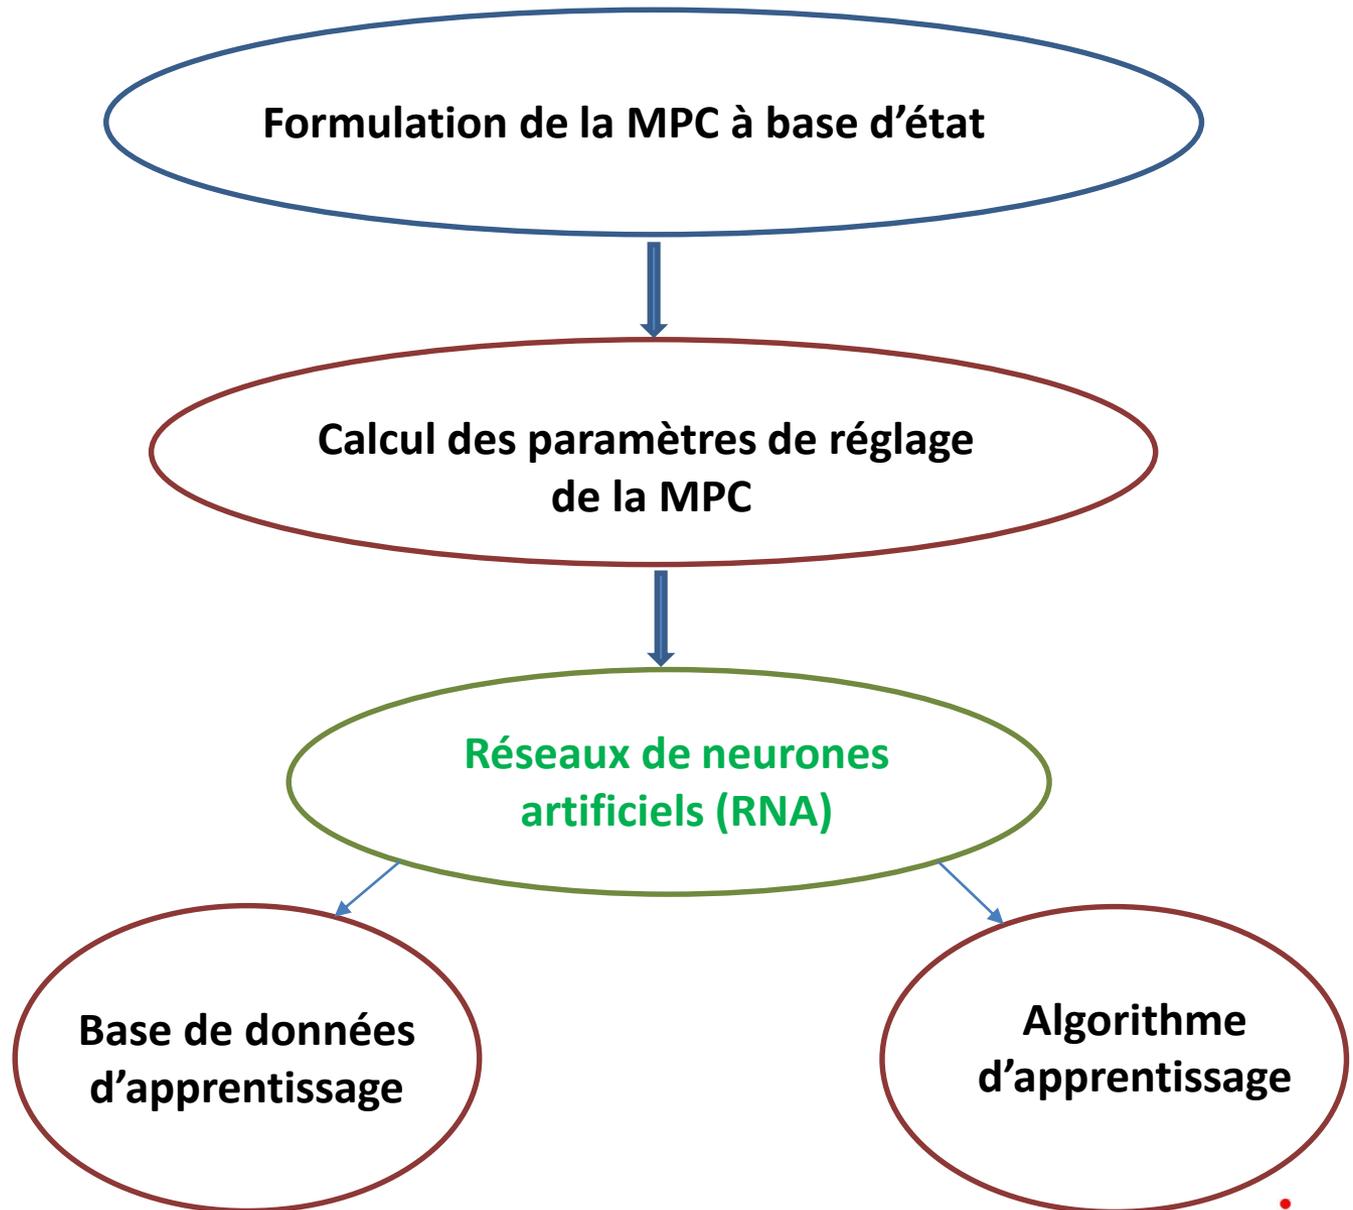
Programmation de la MPC en utilisant le modèle d'état augmenté :

$$J = \sum_{j=0}^{Np} \varepsilon(k+j)^2 + \lambda \sum_{j=0}^{Nc} u(k+j)^2$$

Programmation de la MPC :



Utilisation des RNA :



Construction de la base de données d'apprentissage :

- Calcul des paramètres de réglage par PSO :

- Calcul des paramètres de réglage de la MPC en utilisant une méthode de réglage paramétrique méta-heuristique par PSO pour 1200 systèmes afin de remplir le vecteur de sortie du RNA [Turki, Benkhoud et Langlois 2017].

- Critères de performances considérés :

1. Temps de montée (RT)
2. Temps de réponse (ST)
3. Dépassement (OV)



Apprentissage des RNA :

Il existe trois paradigmes d'apprentissage (A. I. Galushkin, 2007) :

- **Apprentissage par renforcement** : l'apprentissage d'une base de données d'entrées-sorties est exécuté par une interaction continue avec l'environnement pour minimiser un critère de performance.
- **Apprentissage non supervisé** : quand on ne dispose pas des données de sorties. Le but est d'avoir une généralisation sur les données d'entrée.
- **Apprentissage supervisé** : l'apprentissage supervisé peut avoir lieu quand on dispose de toutes les données des variables d'entrées (X) et de sorties (Y).

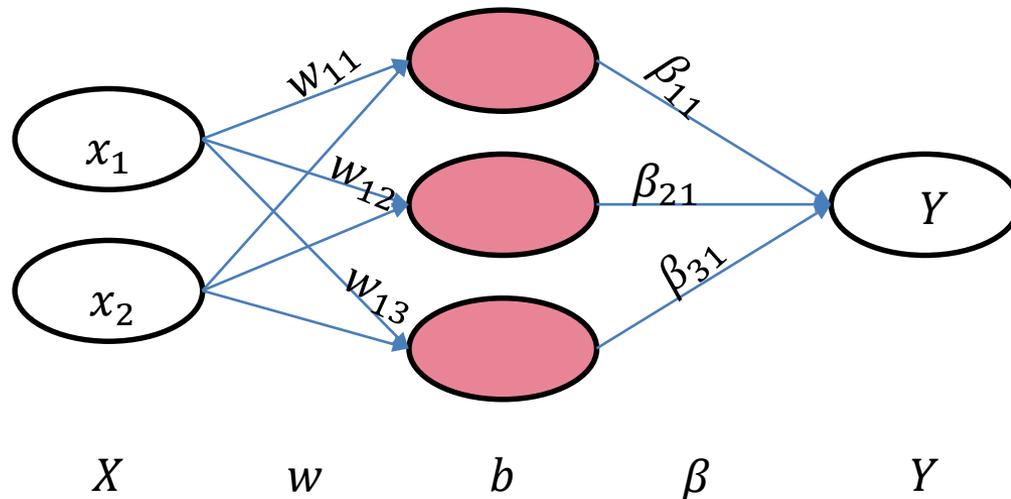
Apprentissage des réseaux de neurones

- Apprentissage en ligne.
- Apprentissage hors ligne.

Apprentissage du Réseau de Neurones Artificiels :

Algorithme On-line Extreme Learning Machine :

- Nécessite une seule couche cachée.
- 1) Initialisation aléatoire des poids w_{ij} entre les neurones de la couche d'entrée et de la couche cachée,
 - 2) Initialisation aléatoire des biais b des neurones de la couche cachée,
 - 3) Imposer un critère d'arrêt sur l'erreur ou le nombre de présentations d'exemples,
 - 4) Calcul des poids β_{i1} entre les neurones de la couche cachée et ceux de la couche de sortie par la méthode des moindres carrés (YibinYe, 2015).



Apprentissage du Réseau de Neurones Artificiels :

$$y_j = \sum_{i=1}^M \beta_i f(w_i x_j + b_i), \quad j \in [1, N]$$

(YibinYe, 2015)

f : la fonction d'activation

L'équation précédente peut se présenter sous forme vectorielle :

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}$$

H est la matrice de sortie de la couche cachée définie par :

$$\mathbf{H} = \begin{pmatrix} f(w_1 x_1 + b_1) & \dots & \dots & \dots & f(w_M x_1 + b_M) \\ f(w_1 x_2 + b_1) & \dots & \dots & \dots & f(w_M x_2 + b_M) \\ \vdots & & & \vdots & \\ \vdots & & & \vdots & \\ f(w_1 x_N + b_1) & \dots & \dots & \dots & f(w_M x_N + b_M) \end{pmatrix}$$

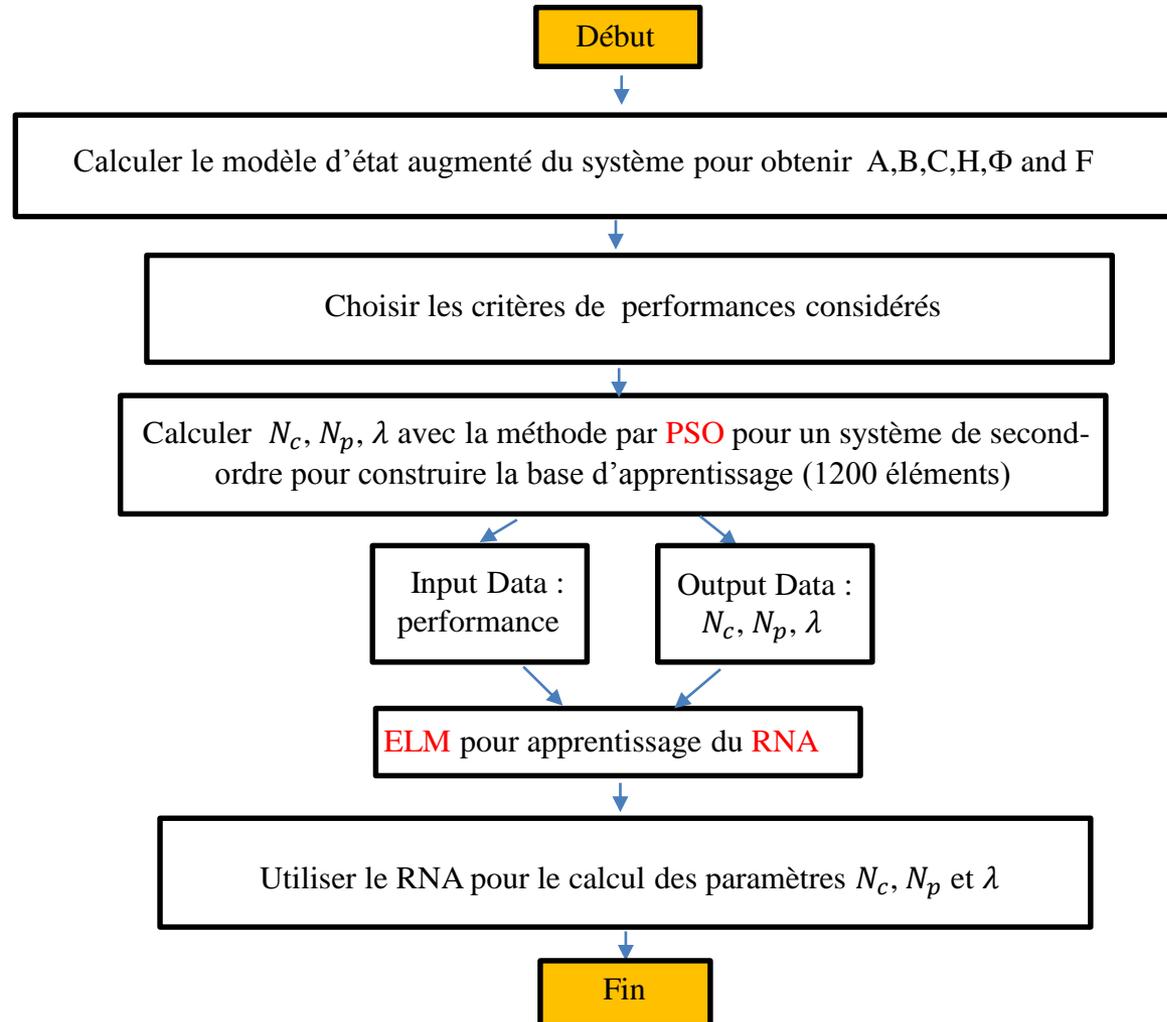
$$\boldsymbol{\beta} = (\beta_1 \dots \dots \beta_M)^T \quad \text{et} \quad \mathbf{y} = (y_1 \dots \dots y_N)^T$$

La détermination du vecteur $\boldsymbol{\beta}$ est faite analytiquement par la résolution de l'erreur quadratique selon la méthode des moindres carrés :

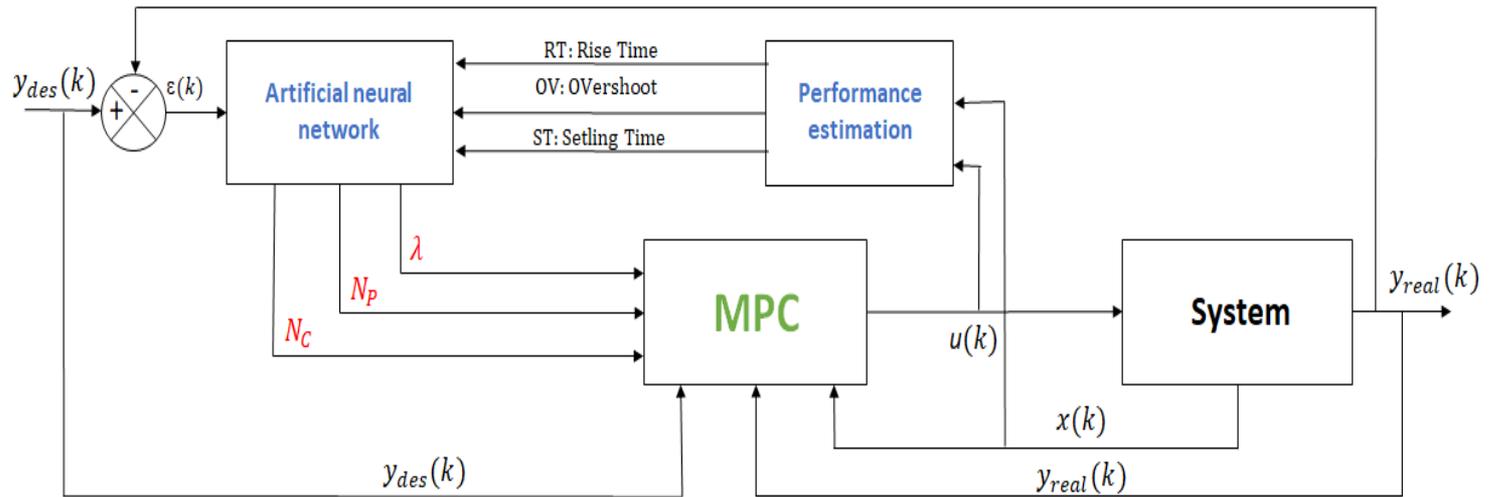
$$S = \|\mathbf{H}\boldsymbol{\beta} - \mathbf{Y}\|^2 = 0$$

$$\boldsymbol{\beta} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H} \times \mathbf{Y} = \mathbf{H}^+ \times \mathbf{Y}$$

- Méthode de réglage proposée :



- Structure de commande associée :



- Application numérique 1 :

Système considéré :

Un moteur électrique avec transmission flexible modélisé par une fonction de transfert de deuxième ordre (Dumur, Boucher 2000) :

$$G(s) = \frac{\Omega(s)}{V(s)} = \frac{K_n}{J_n s^2 + f_n s + C_n}$$

avec $\begin{cases} K_n = 2Nm.rad/s/V \\ J_n = 0.002Kg.m^2 \\ f_n = 0.006Nm/rad/s \\ C_n = 2Nm \end{cases}$ et $\omega_n = \sqrt{\frac{C_n}{J_n}} = 31.623 rad.s^{-1}$, $\xi = \frac{f_n}{2\omega_n J_n}$

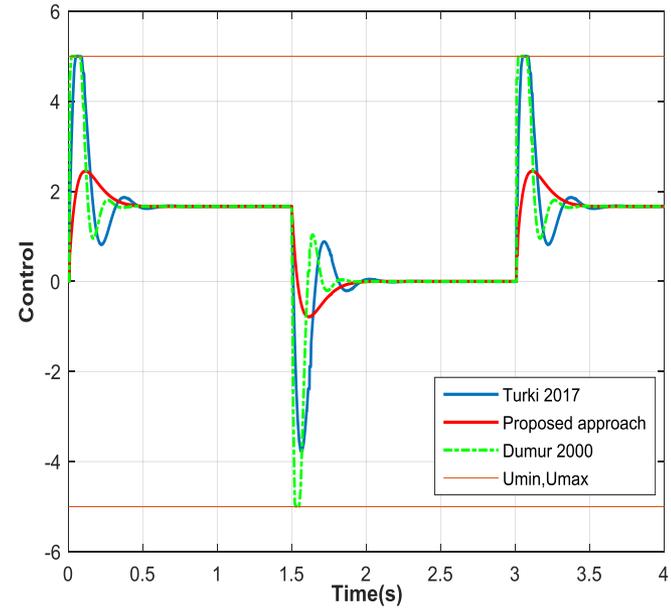
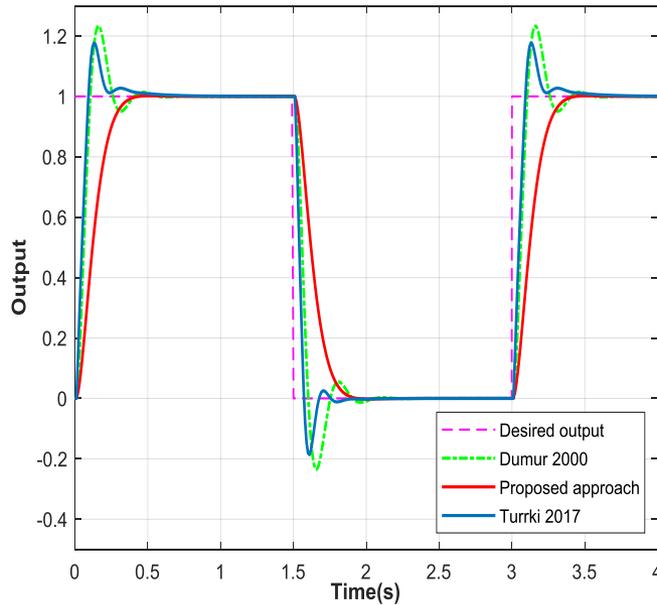
Contraintes sur la commande :

$$\begin{cases} U_{min} = -5V \\ U_{max} = +5V \end{cases}$$

Paramètres de réglage de la MPC :

Méthode	Nc	Np	λ
Dumur 2000	1	8	0,42
Turki 2017	2	10	0,02
Approche proposée	4	39	5

Résultats de simulation :



Comparaison en performances :

	Dumur 2000	Approche proposée	Turki 2017
Dépassement (%)	23	0,1	16
Temps de montée (s)	0,29	0,41	0,26
Temps de réponse (s)	0,69	0,47	0,61
Erreur de poursuite	0,87	0,009	0,48

- Application numérique 2 :

Systeme considéré :

Un système du premier ordre avec retard (Schwarz and al., 2010) :

$$G(s) = \frac{1}{1+0,5s} e^{-s}$$

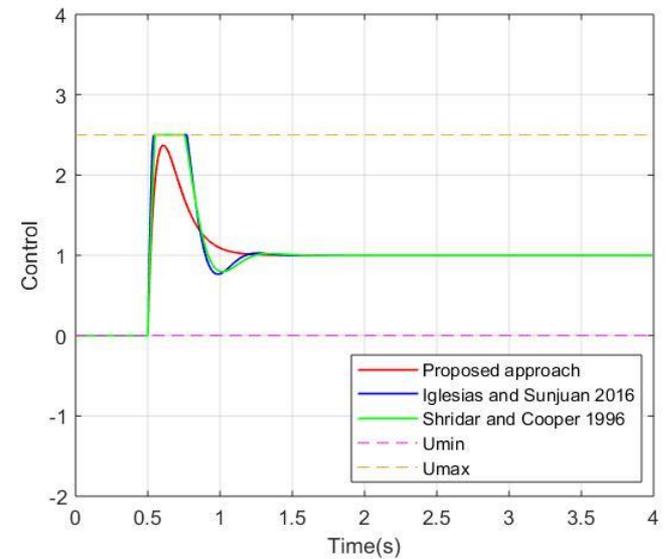
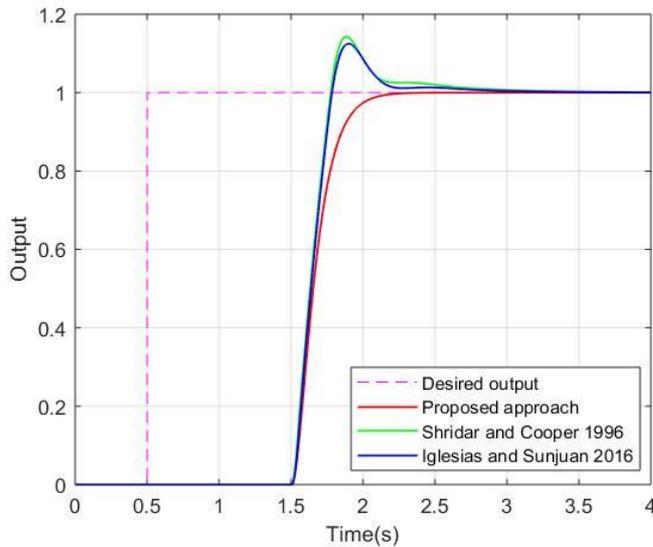
Contraintes sur la commande :

$$\begin{cases} U^{min} = 0 \\ U^{max} = 2.5 \end{cases}$$

Paramètres de réglage de la MPC :

Méthode	Nc	Np	λ
Schridar and cooper 1997	21	61	1,134
Iglesias and sunjuan 2006	18	61	2,166
Approche proposée	5	35	3,148

Résultats de simulation :



Comparaison en performances :

	Schridar and cooper 1997	Approche proposée	Iglesias and sunjuan 2006
Dépassement (%)	11,76	0,5	10,55
Temps de montée (s)	0,127	0,249	0,152
Temps de réponse (s)	0,65	0,39	0,53
Erreur de poursuite	0,58	0,209	0,47

- Travaux en cours :
 - Prise en compte des contraintes (sur la sortie et sur les variables d'état) au niveau de la MPC.
 - Robustesse en performances de l'approche proposée face à des perturbations et sur des systèmes variant dans le temps.
 - Application de l'approche proposée sur des systèmes MIMO découplables.

- Travaux à venir :
 - Construction d'une base de données d'apprentissage à partir de systèmes MIMO.
 - Programmation de la commande prédictive avec les réseaux de neurones sur un système MIMO.
 - Application à un système proposé par Segula Technologies.



Merci pour votre attention