

Εφαρμοσμένη Βελτιστοποίηση: Αναγνώριση Δυναμικών Συστημάτων & Προβλεπτικός Έλεγχος με Μοντέλο

**Χαράλαμπος Μπεχλιούλης, Αναπληρωτής
Καθηγητής**

Τμήμα Ηλεκτρολόγων Μηχανικών & Τεχνολογίας Υπολογιστών

16 Δεκεμβρίου 2025



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΠΑΤΡΩΝ
UNIVERSITY OF PATRAS

Τμήμα Ηλεκτρολόγων Μηχανικών
& Τεχνολογίας Υπολογιστών



Τμήμα Ηλεκτρολόγων Μηχανικών
& Τεχνολογίας Υπολογιστών

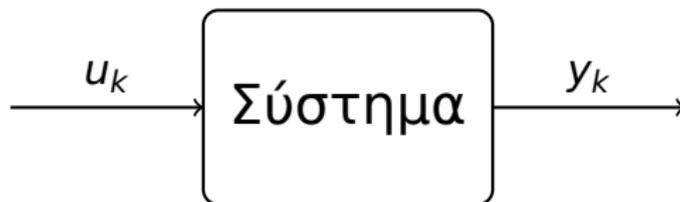
- 1 Εισαγωγή στα Δυναμικά Συστήματα
- 2 Αναγνώριση Συστημάτων ως Πρόβλημα Βελτιστοποίησης
- 3 Προβλεπτικός Έλεγχος με χρήση Εκτιμώμενου Μοντέλου

Τι είναι ένα Δυναμικό Σύστημα;

Ένα δυναμικό σύστημα περιγράφει την εξέλιξη της κατάστασης ενός φυσικού φαινομένου.

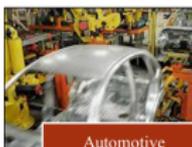
$$x_{k+1} = f(x_k, u_k, w_k), \quad y_k = g(x_k, v_k)$$

- x_k : εσωτερική κατάσταση
- u_k : είσοδος/έλεγχος
- y_k : μετρούμενη έξοδος
- w_k, v_k : θόρυβος/διαταραχές



Εφαρμογές Δυναμικών Συστημάτων

- **Αεροναυτική:** drones, quadrotors, UAV
- **Ρομποτική:** βραχίονες, κινητά ρομπότ
- **Αυτοκινητοβιομηχανία:** cruise control, autonomous driving
- **Ενέργεια:** θερμικά συστήματα, διαχείριση φορτίου
- **Βιολογία:** population dynamics



Automotive



Biology



Energy



Health



Transportation



Aerospace



Robotics



Manufacturing



Environment

Τι είναι Αναγνώριση Δυναμικών Συστημάτων;

Στόχος: από δεδομένα εισόδου-εξόδου να βρούμε ένα **μοντέλο**.

$$x_{k+1} = f(x_k, u_k; \theta)$$

$$\theta^* = \arg \min_{\theta} \sum_{k=1}^N (y_k - \hat{y}_k(\theta))^2$$

Απαιτείται:

- Για σχεδίαση ελέγχου (MPC, LQR)
- Για προσομοίωση/πρόβλεψη
- Για διάγνωση βλαβών

Χωρίς σωστό μοντέλο → δεν υπάρχει αξιόπιστος έλεγχος.

- Το MPC απαιτεί προβλέψιμη εξέλιξη του συστήματος
- Τα δεδομένα αισθητήρων έχουν θόρυβο (Φίλτρο Kalman)
- Οι παράμετροι αλλάζουν με τον χρόνο (aging)

$$J(\theta) = \sum_{k=1}^{N-1} (y_k - \hat{y}_k(\theta))^2$$

$$\theta^* = \arg \min_{\theta} J(\theta)$$

- Least Squares (LS)
- Gradient Descent (GD)
- Gauss-Newton
- Levenberg-Marquardt

Παράδειγμα:

$$\hat{y}_k = \phi_k^\top \theta$$

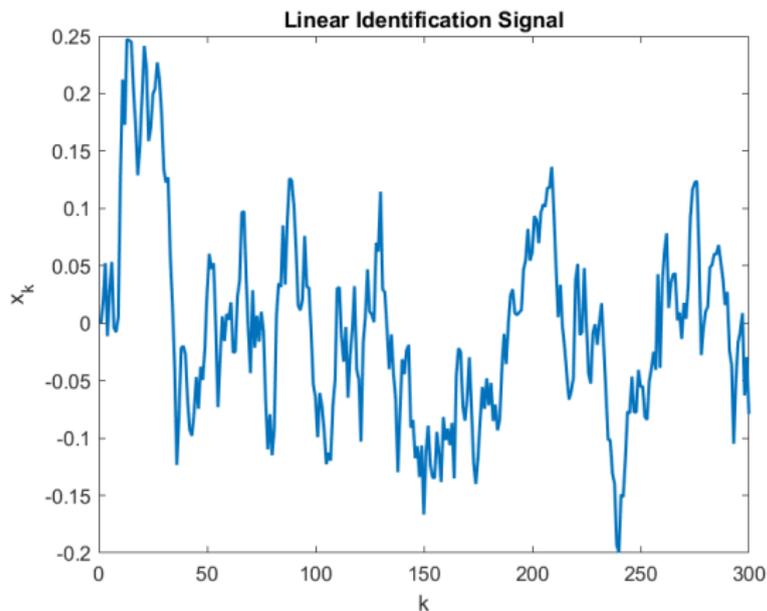
$$x_{k+1} = \alpha x_k + \beta u_k$$

$$\theta = [\alpha, \beta]$$

$$\theta^* = (\Phi^\top \Phi)^{-1} \Phi^\top Y$$

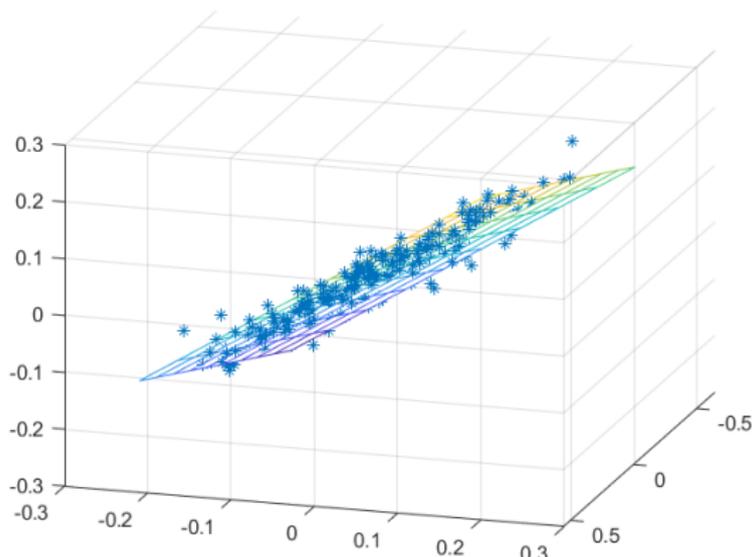
Παράδειγμα

$$x_{k+1} = 0.92x_k + 0.15u_k + \nu_k$$



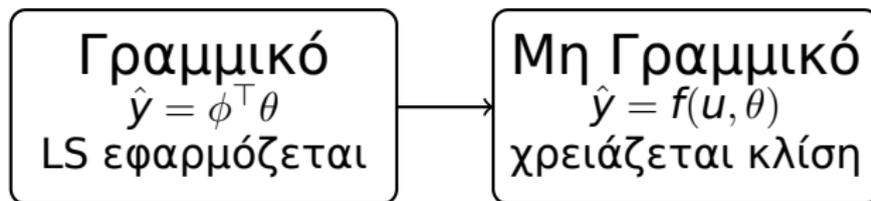
Παράδειγμα

$$x_{k+1} = 0.92x_k + 0.15u_k + n_k$$



$$\theta = [0.8936, 0.1507]$$

Γραμμικό vs Μη-γραμμικό ως προς Παραμέτρους



Το μοντέλο:

$$\hat{y} = f(u, \theta)$$

δεν γράφεται ως $\phi^T \theta$.

Παράδειγμα: $\omega_{k+1} = \omega_k + dt(a\omega_k + bu_k^c)$

Η παράμετρος c μπαίνει ως εκθέτης \rightarrow μη γραμμικό ως προς παραμέτρους.

Μη-Γραμμικό ως προς Παραμέτρους Παράδειγμα

Drone pitch model:

$$\omega_{k+1} = \omega_k + dt(a\omega_k + bu_k^c)$$

$$\theta = [a, b, c]$$

$$e_k = \omega_{k+1} - \hat{\omega}_{k+1}(\theta)$$

$$J = \sum e_k^2$$

Δεν υπάρχει κλειστή λύση \rightarrow iterative optimization.



Τμήμα Ηλεκτρολόγων Μηχανικών
& Τεχνολογίας Υπολογιστών

$$\theta_{i+1} = \theta_i - \alpha \nabla J(\theta_i)$$

$$\nabla J = 2 \sum \mathbf{e}_k \frac{\partial \mathbf{e}_k}{\partial \theta}$$

Πλεονεκτήματα:

- Καθολική εφαρμογή

Μειονεκτήματα:

- Αργή σύγκλιση
- Ευαισθησία στο βήμα α

Παράγωγοι για μη-γραμμικά παραμετροποιημένο μοντέλο

$$\frac{\partial \mathbf{e}_k}{\partial a} = -dt \omega_k$$

$$\frac{\partial \mathbf{e}_k}{\partial b} = -dt u_k^c$$

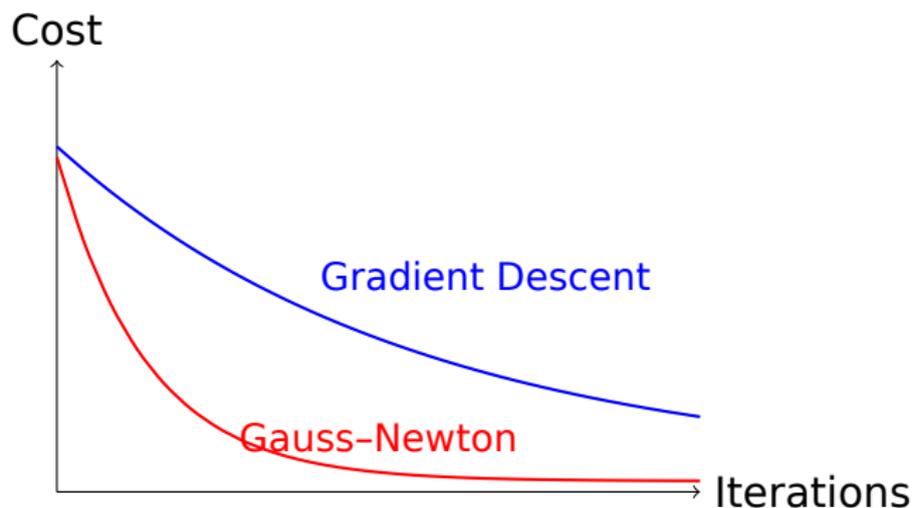
$$\frac{\partial \mathbf{e}_k}{\partial c} = -dt b u_k^c \ln(u_k)$$

$$\theta_{i+1} = \theta_i - (J_{\theta}^{\top} J_{\theta})^{-1} J_{\theta}^{\top} \mathbf{e}$$

Πλεονεκτήματα:

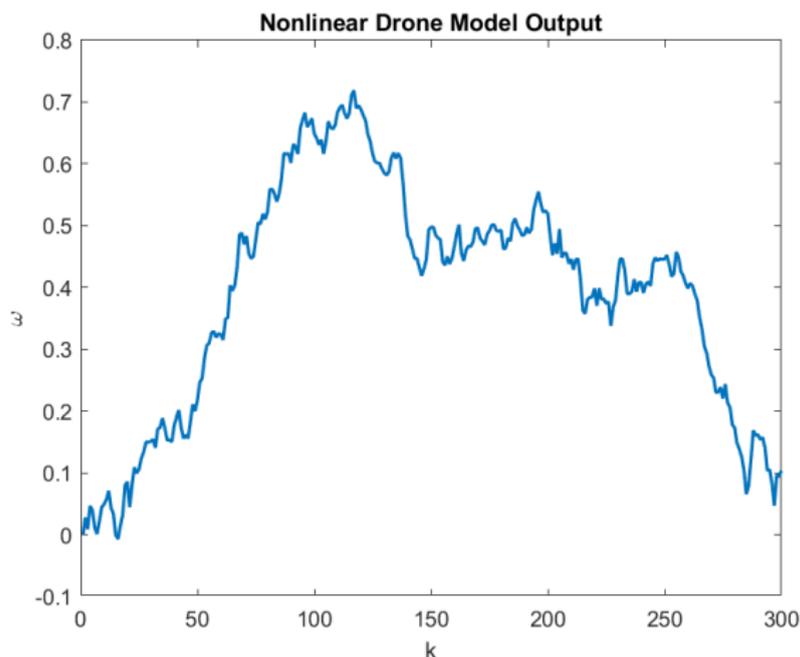
- Πολύ γρήγορη σύγκλιση
- Ιδανικό για μη-γραμμικά μοντέλα

Σύγκριση Σύγκλισης



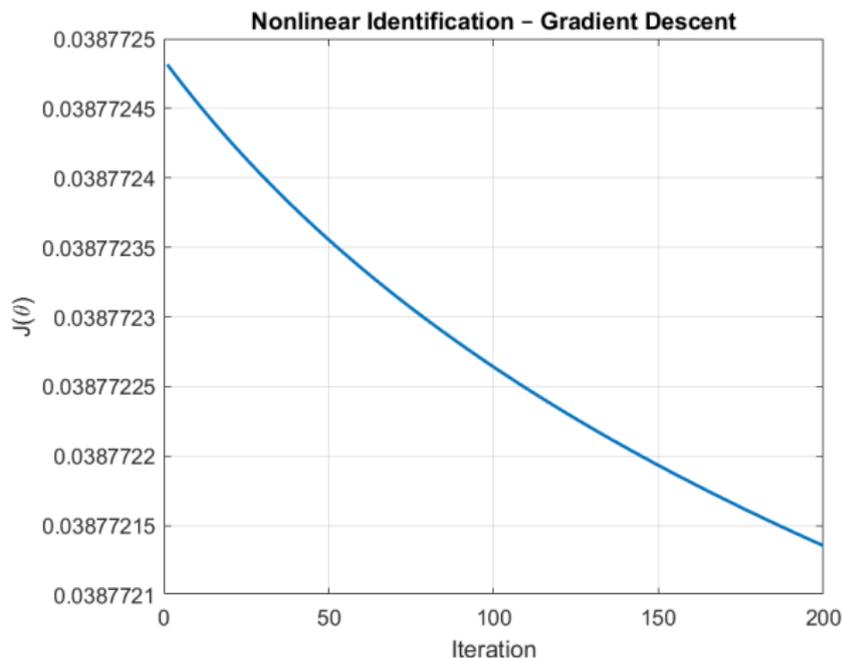
Παράδειγμα: Pitch Dynamics

$$\omega_{k+1} = \omega_k + 0.02(-0.45\omega_k + 0.25u_k^{0.8}) + \nu_k$$



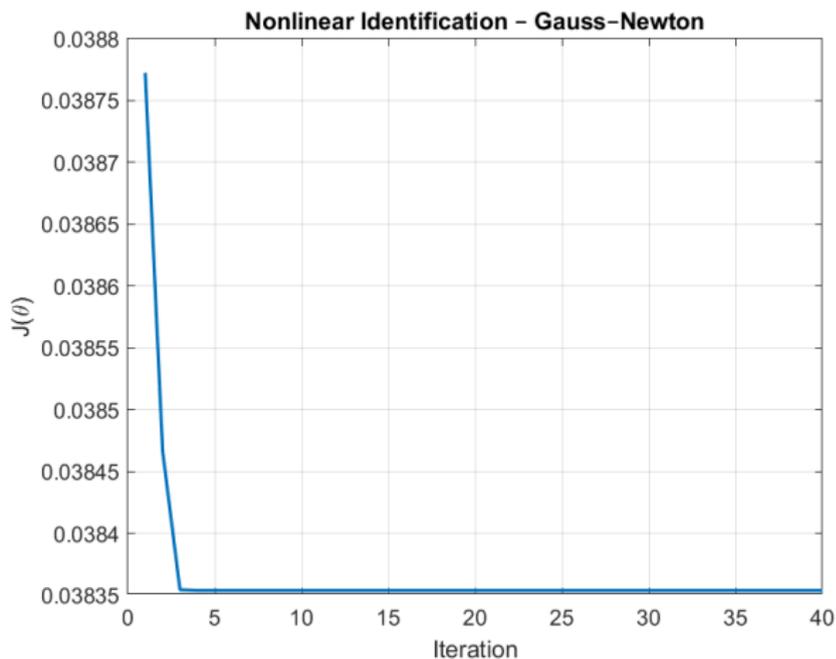
Παράδειγμα: Gradient Descent

$$[a, b, c] = [-0.1160, 0.0871, 0.5026]$$



Παράδειγμα: Gauss-Newton

$$[a, b, c] = [-0.4229, 0.1831, 0.6585]$$



Τα Βήματα της Αναγνώρισης

- 1 Συλλογή δεδομένων
- 2 Επιλογή δομής μοντέλου
- 3 Αρχική εκτίμηση παραμέτρων
- 4 Iterative optimization
- 5 Validation

Τι είναι ο Προβλεπτικός Έλεγχος με Μοντέλο (Model Predictive Control - MPC);

Το MPC είναι μέθοδος ελέγχου που επιλύει ένα πρόβλημα βελτιστοποίησης **σε πραγματικό χρόνο**.

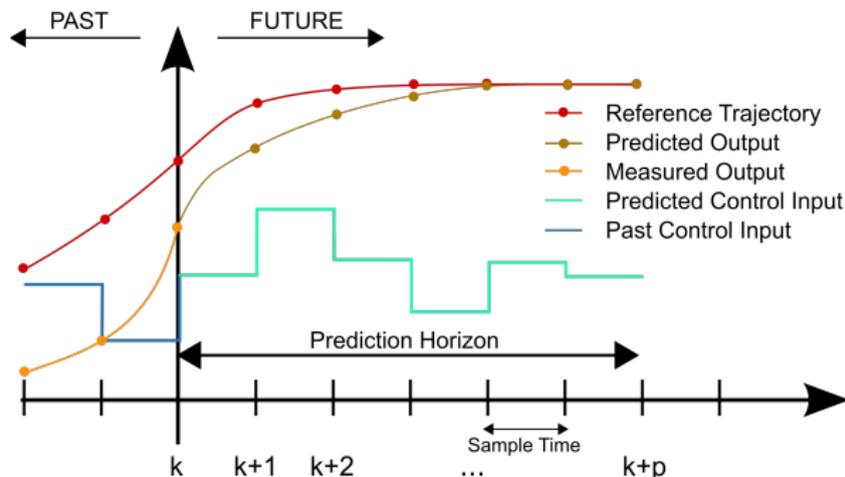
$$\min_{u_{0:N-1}} \sum_{k=0}^{N-1} (x_k^\top Q x_k + u_k^\top R u_k)$$

Περιορισμοί:

$$x_{k+1} = f(x_k, u_k), \quad u_{\min} \leq u_k \leq u_{\max}$$

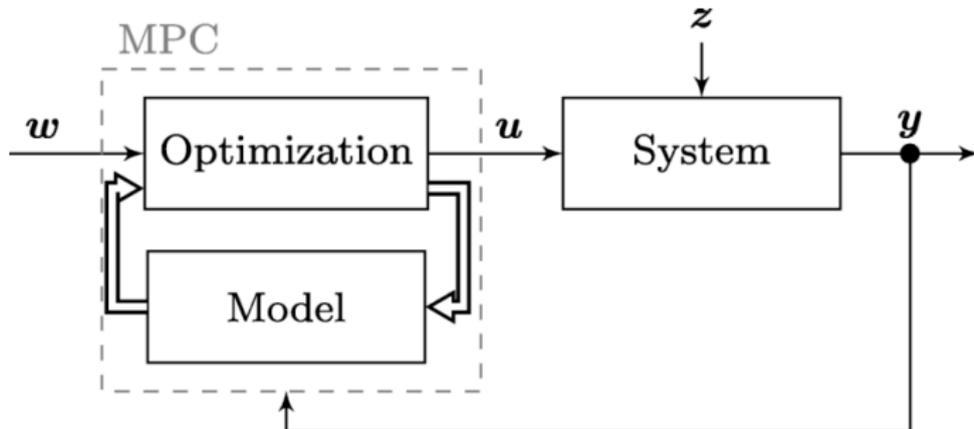
Η βασική ιδέα

- 1 Προβλέπεις μελλοντικές καταστάσεις (prediction)
- 2 Επιλέγεις είσοδο που ελαχιστοποιεί κόστος (optimization)
- 3 Εφαρμόζεις μόνο το πρώτο control input (receding horizon)



Γιατί MPC;

- Χειρίζεται ρητά περιορισμούς (inputs & states)
- Προβλεπτικός έλεγχος - αξιοποιεί μοντέλο
- Λειτουργεί και με μη γραμμικά συστήματα



Για σύστημα:

$$x_{k+1} = Ax_k + Bu_k$$

MPC πρόβλημα:

$$\min_U (X - X_{\text{ref}})^T Q (X - X_{\text{ref}}) + U^T R U$$

Η λύση είναι Quadratic Programming (QP).

Για prediction horizon N :

$$X = \mathcal{A}x_0 + \mathcal{B}U$$

όπου:

$$\mathcal{A} = \begin{bmatrix} A \\ A^2 \\ \vdots \\ A^N \end{bmatrix}, \quad \mathcal{B} = \begin{bmatrix} B & 0 & \dots \\ AB & B & \dots \\ \vdots & & \ddots \end{bmatrix}$$

Το πρόβλημα βελτιστοποίησης γίνεται:

$$\min_U \frac{1}{2} U^T H U + f^T U$$

με περιορισμούς:

$$G U \leq h$$

Ο πίνακας H είναι συμμετρικός και θετικά ορισμένος.

Τα constraints οδηγούν σε συνθήκες ΚΚΤ:

$$\begin{aligned}\nabla_U L(U, \lambda) &= 0 \\ GU \leq h, \quad \lambda \geq 0, \quad \lambda^\top (GU - h) &= 0\end{aligned}$$

Αλγόριθμοι:

- Active-set
- Interior-point
- Gradient-based MPC

Παράδειγμα: Drone altitude MPC

Κατάσταση:

$$x = \begin{bmatrix} h \\ v \end{bmatrix}$$

Έλεγχος:

$$u = \text{thrust}$$



$$h_{k+1} = h_k + dt v_k$$

$$v_{k+1} = v_k + dt k u_k$$

Σε μορφή $x_{k+1} = Ax_k + Bu_k$.

$$A = \begin{bmatrix} 1 & dt \\ 0 & 1 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ k dt \end{bmatrix}$$

Παράδειγμα: Trajectory Tracking

Στόχος:

$$\min \sum (x_k - x_{\text{ref}})^T Q (x_k - x_{\text{ref}}) + \rho u_k^2$$

- $N_{\text{pred}} = 20$
- $Q = \text{diag}(1, 0.1)$
- $\rho = 0.05$

Απαραίτητο: σωστό μοντέλο από αναγνώριση!

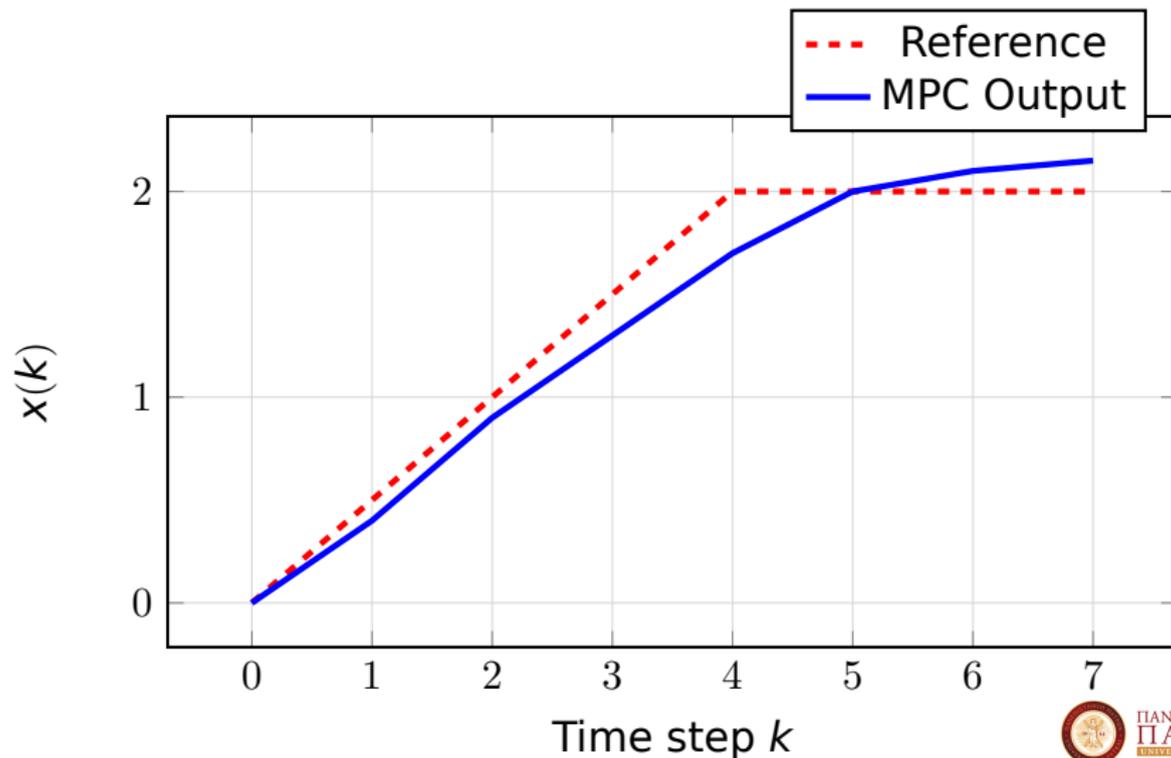
```
u_opt = quadprog(H,f,[],[],[],[],umin*ones(N,1),umax*ones(N,1));
```

Στη συνέχεια:

$$u_0 = u_{\text{opt}}(1)$$

και εφαρμόζεται στο σύστημα.

Παράδειγμα Plot: MPC Tracking



Για μη-γραμμικό σύστημα:

$$x_{k+1} = f(x_k, u_k)$$

Το optimization γίνεται μη-γραμμικό:

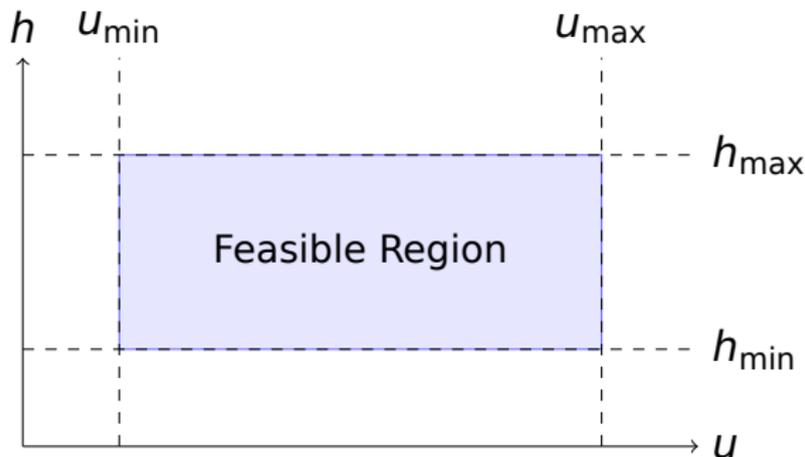
$$\min_U \sum \|x_k - x_k^{ref}\|_Q^2 + \|u_k\|_R^2$$

Επιλύεται με SQP ή nonlinear interior point.

State & Input Constraints

$$u_{\min} \leq u_k \leq u_{\max}$$

$$h_{\min} \leq h_k \leq h_{\max}$$



- Βέλτιστη χρήση ενεργοποιητών
- Προβλεπτική συμπεριφορά
- Λειτουργεί σε complex συστήματα

Το παρόν σετ ασκήσεων ασκεί τον φοιτητή:

- στην αναγνώριση παραμέτρων δυναμικών μοντέλων,
- στη χρήση Gradient Descent και Gauss-Newton,
- στη διαμόρφωση και επίλυση MPC προβλημάτων,
- στην εφαρμογή MPC για παρακολούθηση τροχιάς.

Άσκηση 1: Γραμμική Αναγνώριση

Δίνεται σύστημα:

$$x_{k+1} = \alpha x_k + \beta u_k + w_k$$

Ζητείται:

- 1 Να δημιουργήσετε dataset με τυχαίο u_k .
- 2 Να υπολογίσετε α, β με Least Squares.
- 3 Να σχεδιάσετε την πραγματική και την εκτιμώμενη έξοδο.

Άσκηση 2: Μη-Γραμμική Αναγνώριση

Μη γραμμικό μοντέλο:

$$\omega_{k+1} = \omega_k + dt(a\omega_k + b u_k^c)$$

Ζητείται:

- 1 Να εφαρμόσετε Gradient Descent.
- 2 Να εφαρμόσετε Gauss-Newton.
- 3 Να συγκρίνετε τις καμπύλες σύγκλισης.

Άσκηση 3: Κατασκευή Γραμμικού MPC

Για:

$$x_{k+1} = Ax_k + Bu_k$$

Ζητείται:

- 1 Δημιουργία prediction matrices A, B .
- 2 Κατασκευή πίνακα κόστους H και διανύσματος f .
- 3 Επίλυση QP με quadprog.

Δίνεται:

$$h_{k+1} = h_k + dt v_k$$

$$v_{k+1} = v_k + dt(-g + k u_k)$$

Ζητείται:

- 1 Υλοποίηση MPC για παρακολούθηση τροχιάς.
- 2 Σχεδίαση $h(t)$, $h_{ref}(t)$ και $u(t)$.
- 3 Ανάλυση της επίδρασης του prediction horizon.