

Construcción sistemática de modelos grises usando regresión con restricciones

José Luis Pitarch, César de Prada, Antonio Sala, Daniel A. Montes

1



Universidad
de Valladolid

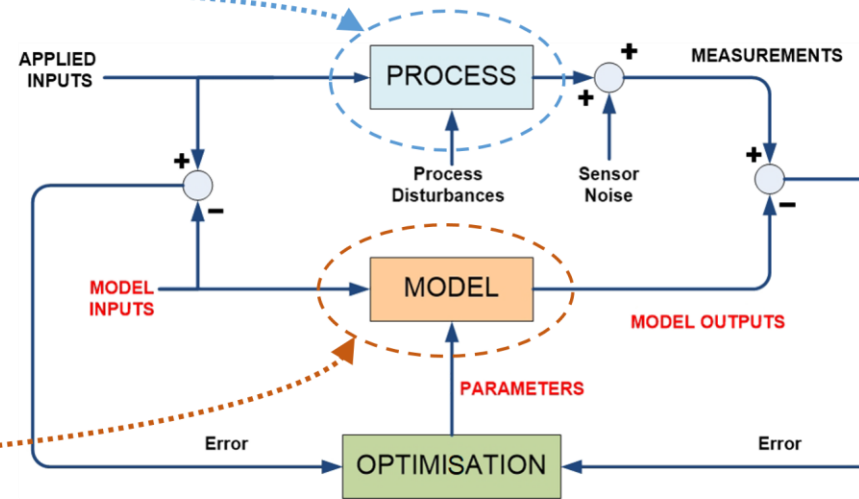
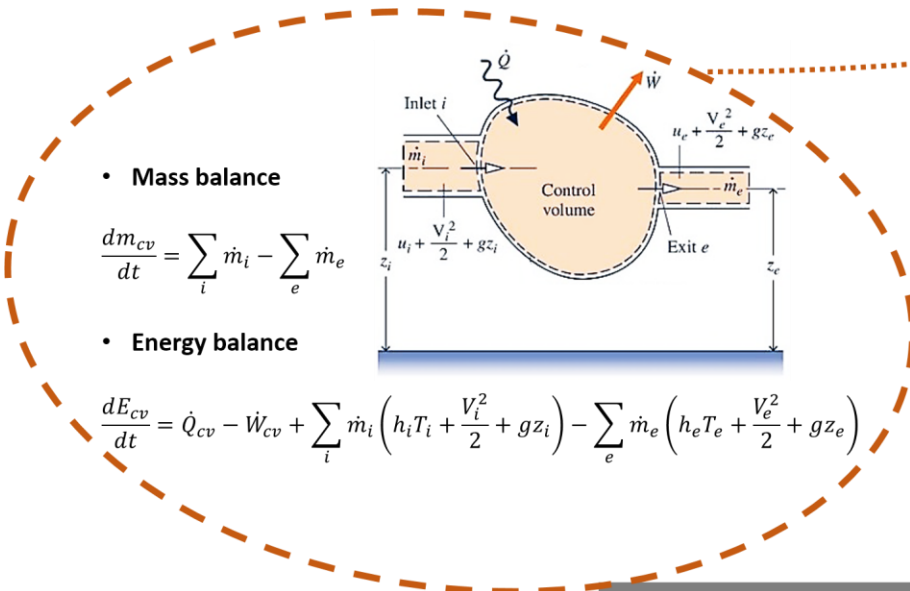
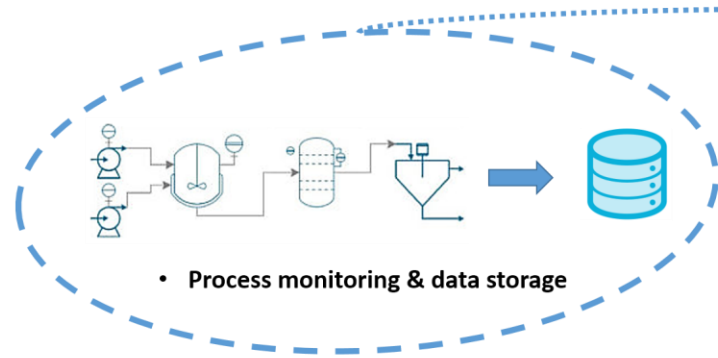


UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

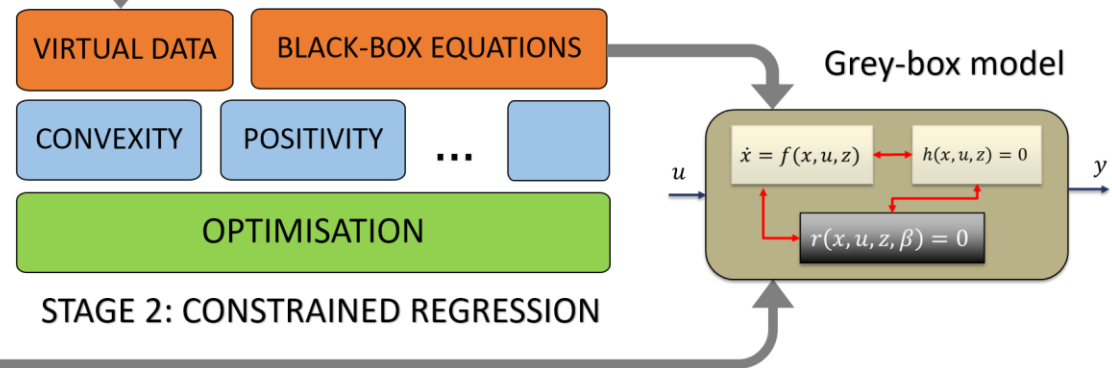
MOTIVACIÓN Y OBJETIVO

- El modelado es el principal cuello de botella en el desarrollo de herramientas avanzadas de soporte a la decisión.
- Se desea tener modelos de proceso representativos y confiables, pero de complejidad limitada, para su uso en control y optimización en línea.
- En ingeniería de procesos se necesita una metodología que vaya más allá del puro aprendizaje máquina:
 - Incluir tanto conocimiento físico/químico disponible como sea posible.
 - Limitar la elevada dependencia en cuanto a cantidad y calidad de los datos disponibles.
 - Extrapolar coherentemente con la física del proceso.

METODOLOGÍA DE MODELADO HÍBRIDO



STAGE 1: ESTIMATION & DATA RECONCILIATION



REGRESIÓN CON RESTRICCIONES

¿Cualquier aprendizaje máquina sirve para obtener los submodelos de caja negra?

- Es bastante probable que NO:
 - Hay muchos datos históricos pero alrededor del mismo punto de operación.
 - Realizar experimentos en una planta en producción es caro y limitado.
- Búsqueda de **modelos subrogados capaces de extrapolar con coherencia.**
- Opciones para obtener modelos de caja negra con restricciones:

1) *Regresión simbólica*

Problema MI(N)LP +
muestreo adaptativo



2) *Physics-informed NN*

Muestreo representativo
+ leyes físicas conocidas
“Restricciones” de igualdad

3) *Regresión polinomial SOS*

Problema SDP (convexo)
Restricciones garantizadas
en toda la región de operación

REGRESIÓN SOS (SUM OF SQUARES)

Programación SOS

- Si un polinomio $p(z)$ es SOS, entonces

$$p(z) \geq 0 \quad \forall z \in \mathbb{R}$$

- Comprobar $p(z) \geq 0$ **localmente** en una región $\Omega(z) := \{z | g_i(z) > 0\}$ intersección de polinomios es “fácil”:

$$p(z) - \sum_{i=1}^m \lambda_i(\alpha; z) \cdot g_i(z) \geq 0$$

$$\lambda_i(\alpha; z) \geq 0$$

P. Parrilo, 2000. *Structured semidefinite programs and semialgebraic geometry methods in robustness and optimization*. PhD. Thesis, CalTech

M. Putinar, 1993. Positive Polynomials on Compact Semi-algebraic Sets. *Indiana University Mathematics Journal*, 42(3), 969-984

Regresión por mínimos cuadrados

$$\text{minimizar}_{\beta} \sum_{i=1}^N (y_{[i]} - p(\beta; x_{[i]}))^2$$

$$\text{s. t. : } c(\beta; x) \geq 0 \quad \forall x \in \Omega := \{x | g(x) > 0\}$$

$$\underline{\beta} \leq \beta \leq \bar{\beta}$$

-Restricciones/cotas en el modelo y en sus **derivadas**:

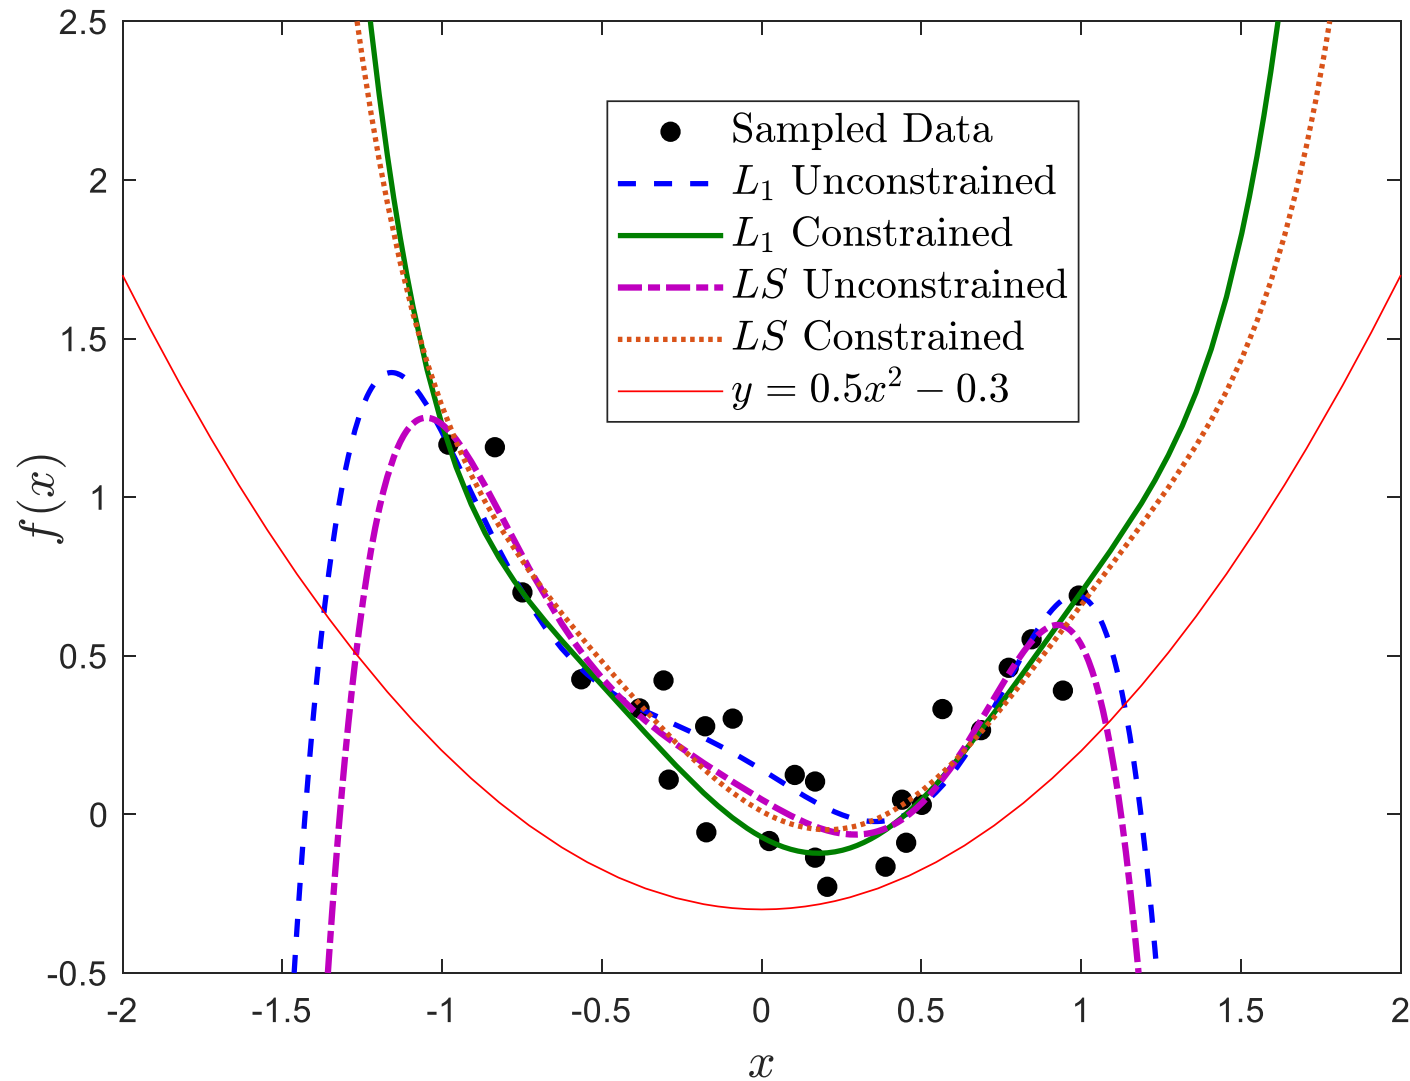
$$\text{Monotonía } \alpha^T \nabla_x p(\beta; x) \geq F$$

$$\text{Curvatura } A^T \cdot \nabla_x^2 f(\beta; x) \cdot A > B$$

$$\text{Convexidad: } H(\beta; x) > 0$$

...

EJEMPLO ACADÉMICO



- Modelo polinomial de hasta grado 6
- Se desea extrapolar al rango $x \in [-2, 2]$


AJUSTE CON NORMAS \mathcal{L}_1 Y \mathcal{L}_2^2

ERRORES DE AJUSTE A DATOS:

	\mathcal{L}_1 norm	\mathcal{L}_2^2 norm
Unconstrained	2.703	0.431
Constrained	2.836	0.4765

CASO INDUSTRIAL

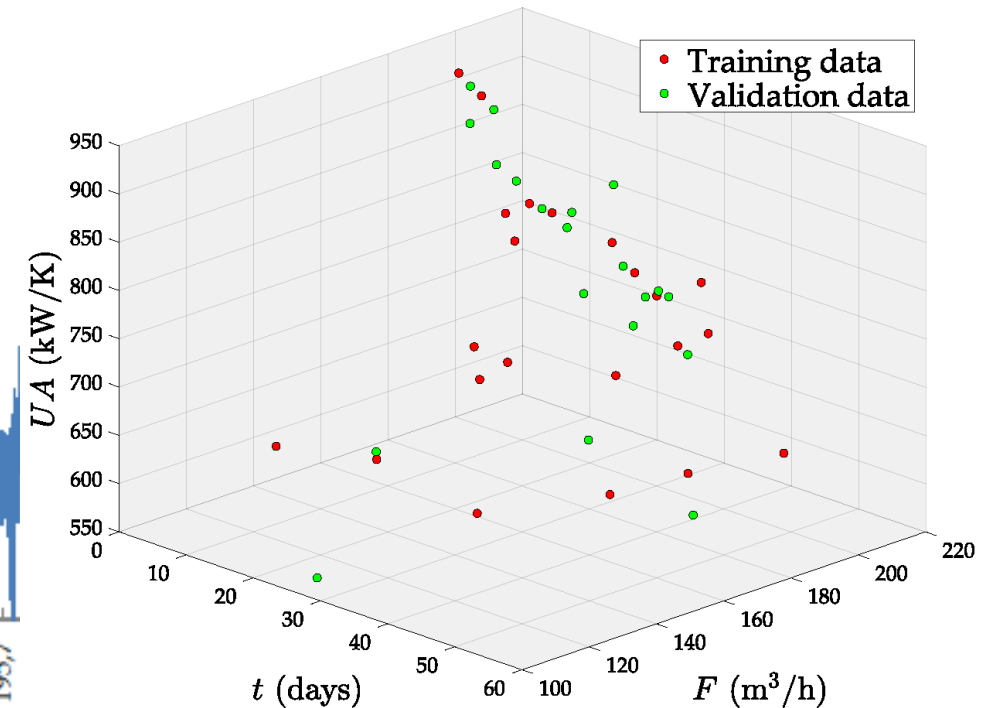
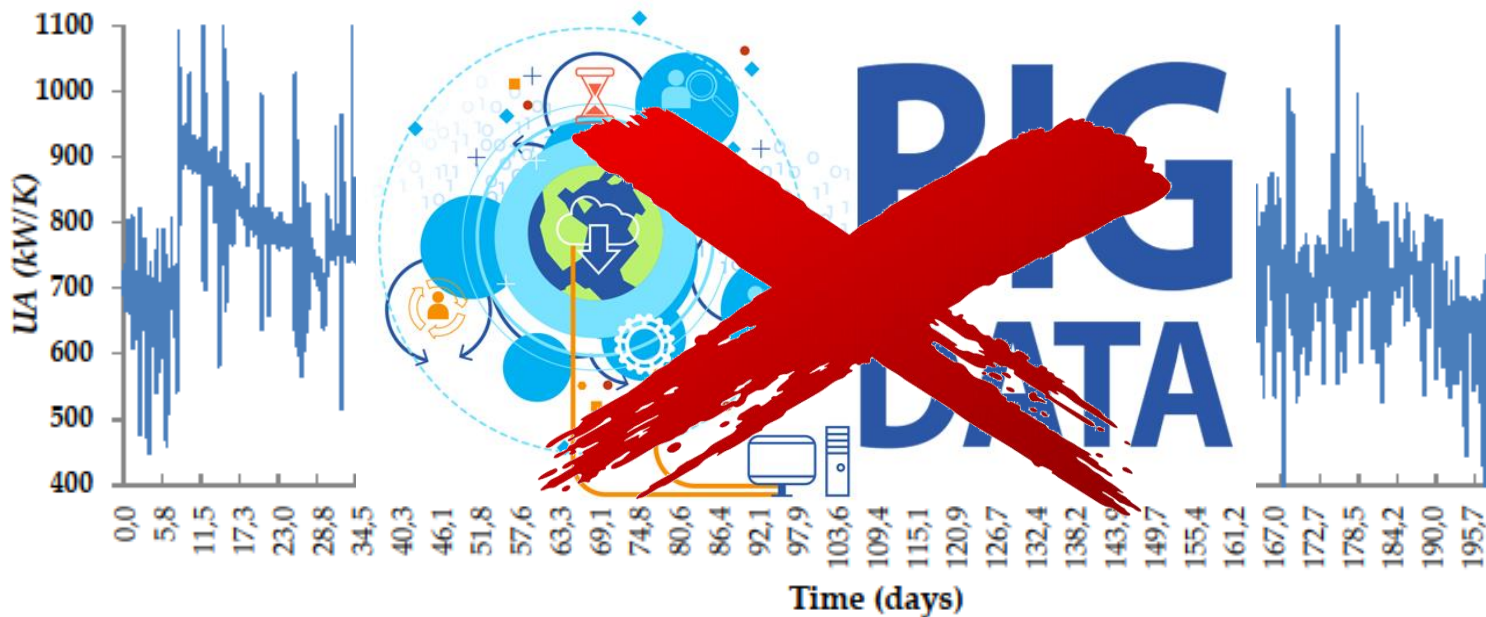
- Modelar el coeficiente global de transmisión de calor UA en una planta de evaporadores:



Estimaciones de UA en $W1$ obtenidas por reconciliación de datos

DATOS DISPONIBLES PARA REGRESIÓN

- Muchas muestras tomadas cada 5 min en 7 meses de operación
- El 98% del tiempo la planta operó con caudales altos



REGRESIÓN CON REGULARIZACIÓN


$$\min_{\beta} \sum_{i=1}^N \left(y_{[i]} - p(\beta; x_{[i]}) \right)^2 + \Gamma \cdot \|\beta\|_1$$

s. t.: $\underline{\beta} \leq \beta \leq \bar{\beta}$

- $\Gamma = \gamma [0, 1, e, e^2, e^3, e^4 \dots]^T$

Metaparámetro que progresivamente penaliza el uso de monomios de grado alto.

- Polinomio de grado 4 en F y t



REGRESIÓN SOS CON RESTRICCIONES

- Cotas en las derivadas parciales:

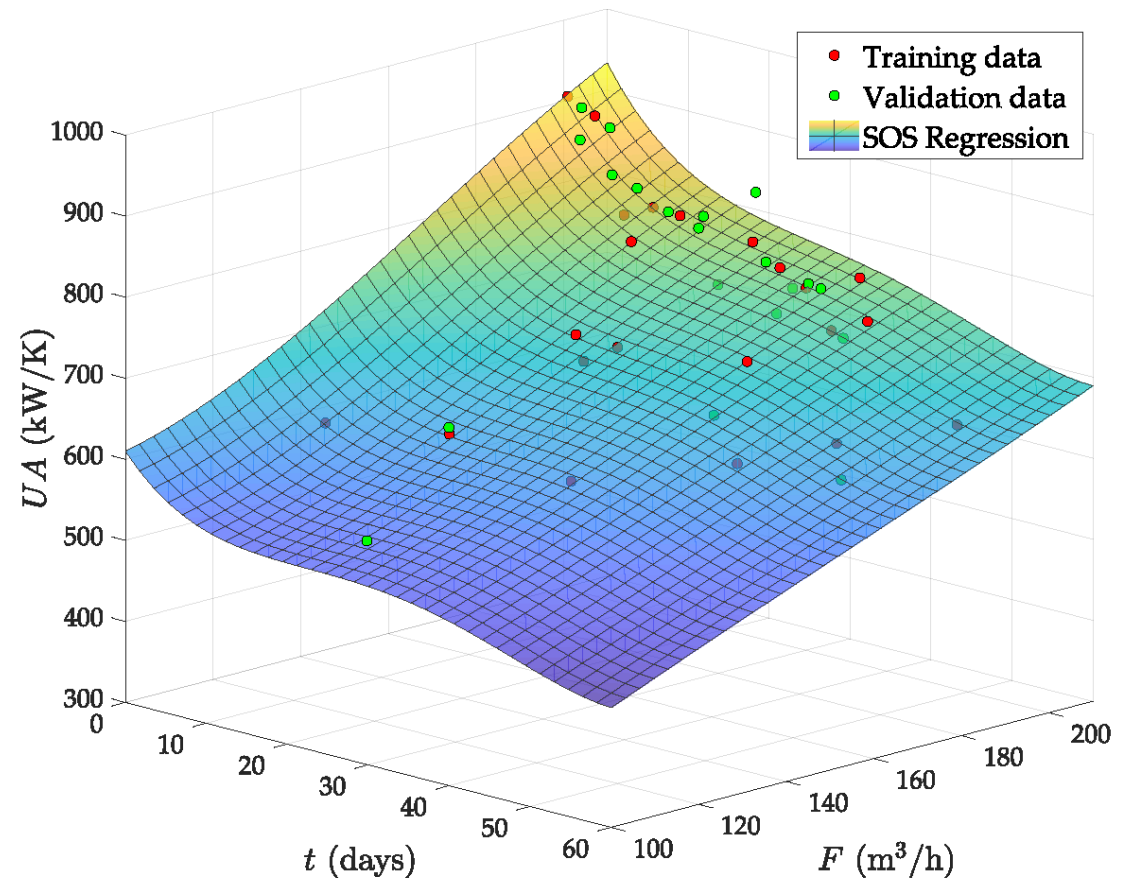
$$\frac{dp(F, t)}{dF} > 0 \quad \forall F, t \in \Omega$$

$$\frac{dp(F, t)}{dt} < 0 \quad \forall F, t \in \Omega$$

$$\frac{dp(F, t)}{dF} < 0,6 \quad \forall F, t \in \Omega \cap \{30 < t < 60\}$$

$$\frac{dp(F, t)}{dt} > -0,6 \quad \forall F, t \in \Omega \cap \{30 < t < 60\}$$

- Mismo grado del polinomio
- El ajuste a datos solo es 1.3% peor



PROGRAMACIÓN



Paso 1. Reconciliación de datos



IPOPT
NLP solver



Paso 2. Regresión SOS

oxfordcontrol/
SOSTOOLS



sqlp/**sedumi**



CONCLUSIONES

- La metodología de modelado híbrido propuesta **permite incorporar todo el conocimiento disponible** sobre el proceso.
- **Las restricciones SOS se garantizan en cualquier punto** independientemente de los datos disponibles.
- **Los modelos de caja negra se obtienen resolviendo un problema de optimización convexa.**
 - El ejemplo del intercambiador de calor tarda $\sim 1,5$ sec.
- **La regresión SOS está limitada a formas polinomiales**
- **Escalabilidad limitada** por el número de variables independientes y el grado de los polinomios involucrados.
- **No se decide automáticamente el mejor grado de los polinomios**
La selección de funciones base requiere programación mixta-entera
- **La interpretabilidad del modelo se diluye para grados altos**

REFERENCIAS

Contacto:
jlpitarch@isa.upv.es

- Developing Grey-box Dynamic Process Models
C. de Prada, D. Hose, G. Gutierrez, J.L. Pitarch
IFAC-PapersOnLine 51 (2), pp. 523-528
- A Sum-Of-Squares Constrained Regression Approach for Process Modeling
J.L. Pitarch, A. Sala, C. de Prada
IFAC-PapersOnLine 52 (1), pp. 754-759
- Application of SOS-constrained regression to model unknown reaction kinetics
J.L. Pitarch, D.A. Montes, C. de Prada, A. Sala
IFAC-PapersOnLine 54 (3), pp. 395-400
- A systematic grey-box modeling methodology via data reconciliation and SOS constrained regression
J.L. Pitarch, A. Sala, C. de Prada
Processes 7 (3), 170