

# **Simulación a Eventos Discretos**

Tema 12: Metamodelo y optimización

# Superficies de respuesta y metamodelos

- Se busca evaluar el efecto de  $k$  factores en las respuestas de interés.
- *Metamodelo*: establece cómo la simulación transforma valores de los factores de entrada en respuestas de interés.
- El objetivo es predecir las respuestas para otros niveles de factores (que no se han simulado), dado que simular todos puede ser muy costoso.
- Se utilizan técnicas de regresión (primer y segundo orden).

## Ejemplo: $2^2$ diseño factorial

Dos factores ( $s$  y  $d$ ) con dos niveles cada uno ( $-$  y  $+$ ).

El metamodelo es  $E[R(s, d)] = \beta_0 + \beta_s x_s + \beta_d x_d + \beta_{sd} x_s x_d$

- $R(s, d)$  es el valor de la respuesta dependiente de los factores.
- $\beta_0, \beta_s, \beta_d, \beta_{sd}$  son los coeficientes (se ajustan por regresión en base a valores conocidos de la respuesta para los niveles de los factores).
- $x_s$  y  $x_d$  son los valores de los factores.
- Notar que si  $\beta_{sd} = 0$ , significa que no hay interacción entre los factores.

## Estimación de coeficientes

$x_s$  y  $x_d$  se denominan variables codificadas para los respectivos factores. Las originales  $s$  y  $d$  se denominan variables naturales.

Sean  $\bar{s}$  y  $\bar{d}$  los promedios, y  $\Delta s$  y  $\Delta d$  las diferencias, calculadas en base a los valores  $-$  y  $+$  de los factores  $s$  y  $d$ , respectivamente.

Las variables codificadas se definen como

$$x_i = \frac{2(i - \bar{i})}{\Delta i}$$

para  $i = s, d$ . Mapeo al rango  $[-1, 1]$ .

## Estimación de coeficientes

Sean  $\bar{e}_s(n)$ ,  $\bar{e}_d(n)$  y  $\bar{e}_{sd}(n)$  estimaciones de los efectos de los factores  $s$  y  $d$  calculados en base a  $n$  repeticiones independientes (ver tema 10).

Sea  $\bar{R}_F(n)$  el promedio de la respuesta de interés calculada sobre los cuatro puntos simulados y las  $n$  repeticiones independientes.

Los estimadores de mínimos cuadrados para los coeficientes son:

$$\hat{\beta}_0 = \bar{R}_F(n), \quad \hat{\beta}_s = \frac{\bar{e}_s(n)}{2}, \quad \hat{\beta}_d = \frac{\bar{e}_d(n)}{2}, \quad \hat{\beta}_{sd} = \frac{\bar{e}_{sd}(n)}{2}$$

# Metamodelo

- El modelo anterior puede no ser una buena aproximación.
- Alternativa:  $E[R(s, d)] = \beta_0 + \beta_s x_s + \beta_d x_d + \beta_{sd} x_s x_d + \beta_{ss} x_s^2 + \beta_{dd} x_d^2$
- Será necesario contar con más puntos (simulaciones) para ajustar los coeficientes.
- En ambos casos la representación gráfica es una curva en el espacio tridimensional.

## Metamodelo: aplicaciones y extensiones

- Aplicaciones: Optimizar utilizando el metamodelo. Se avanza según el gradiente (del metamodelo) y se estima nuevamente la superficie de respuesta en el entorno del nuevo punto, corriendo nuevas simulaciones.
- Extensiones: Ajuste de modelos para diferentes respuestas. Más factores a la vez.
- Otros métodos: *space-filling designs*, modelos de Kriging y de procesos de Gauss.

# Optimización basada en Simulación

- Factores: cuantitativos (continuos y discretos) o cualitativos.
- Interesa optimizar los factores controlables, y en general es posible hacerlo automáticamente con los cuantitativos.
- Evaluar algunas combinaciones de factores dadas vs. buscar la mejor combinación (modelo descriptivo vs modelo normativo).



## Optimización basada en Simulación: problema

- Se optimiza  $E[R(v_1, v_2, \dots, v_k)]$  donde  $R$  es la respuesta de interés y  $v_i$  es una variable que representa el valor del factor  $i$ .
- Sujeto a restricciones:
  - Simples que involucran una sola variable (por ejemplo, cotas inferior y superior):  $l_i \leq v_i \leq u_i$
  - Combinaciones de variables (por ejemplo, lineal):  
$$a_{j1}v_1 + a_{j2}v_2 + \dots + a_{jk}v_k \leq c_j$$
- El dominio del problema es en el espacio de  $k$  dimensiones; no necesariamente restringido a dos valores por factor.

## Optimización basada en Simulación: solución

- La evaluación de la función objetivo es compleja (implica correr la simulación); dado que las variables son aleatorias, se deben correr varias repeticiones.
- Métodos de resolución del problema de optimización: mecanismos que realizan cambios sistemáticos en los valores de los factores, interactúan con la simulación para evaluar la función objetivo y se detienen según un criterio de parada. No garantizan optimalidad global.
- Metaheurísticas: métodos que guían a otros procedimientos heurísticos de búsqueda para evitar que sean atrapados en óptimos locales.
- Estos métodos tienen más chances de encontrar mejores soluciones (combinaciones de factores) que las que se pueden encontrar a mano.

## Optimización basada en Simulación: práctica

- El problema es difícil de resolver pero hay mucho interés práctico en abordarlo, por los ahorros potenciales (en todo sentido).
- Ejemplos: organización de salas de emergencia en hospitales, plantas de fabricación de autos, gestión de inventarios.
- Paquetes de software que implementan estos métodos: AutoStat, ExtendSim Optimizer, OptQuest, SimRunner, WITNESS Optimizer.

# Características deseables de software para Optimización basada en Simulación

- Calidad de la solución obtenida, tiempo de ejecución.
- Visualización del progreso de la optimización.
- Restricciones lineales y no lineales.
- Restricción sobre el valor objetivo.
- Diferentes criterios de parada.
- Intervalo de confianza para el valor óptimo.

# Características deseables de software para Optimización basada en Simulación

- Cantidad variable de replicaciones, dependiendo de la combinación particular de valores de los factores.
- Control sobre el generador de números seudoaleatorios, por ejemplo, para poder aplicar métodos de reducción de varianza.
- Paralelización, ejecución en la nube.