

Parte II

Estrategias

Capítulo 5

Definición de estrategias

*Luego de haber presentado y comentado brevemente los alcances actuales de la MSR, y mediante algunas técnicas utilizadas en el enfoque clásico y otras que provienen de los MLG, nos abocaremos en esta Parte II a explorar superficies teóricas simuladas, de modo que puedan proponerse criterios objetivos para decidir qué estrategia es la más conveniente. La utilización de datos simulados y de las rutinas de estimación de parámetros mediante aplicaciones del programa **R** serán la clave para evaluar cada una de estas estrategias. Dichas superficies constituirán unas ciertas superficies teóricas, que al mismo tiempo serán las representaciones de los valores esperados de la respuesta¹, alrededor de los cuales se generarán puntos aleatoriamente. Con éstos se ajustarán modelos de primero y segundo orden cuando corresponda, siguiendo la estrategia secuencial de experimentación.*

5.1. Introducción

Al iniciar un estudio de exploración secuencial² de una superficie de respuesta — desconocida— en la que el experimentador pretenda encontrar el lugar geométrico que tiene el valor esperado de una variable respuesta para un cierto grupo de factores bajo su control, se definirá un cierto número de condiciones experimentales de antemano sobre la base de condiciones técnicas y económicas disponibles.

Cuando sobre la base de este control sobre los niveles de los factores sea posible realizar observaciones del valor esperado de la superficie de respuesta, se podrán ajustar funciones de aproximación de la respuesta verdadera, cuyos parámetros deberán

¹Recordemos que para una distribución binomial y , de índices m y $\pi(\mathbf{x}, \boldsymbol{\beta})$, su valor esperado estará dado por: $E(y | \mathbf{x}) = m\pi(\mathbf{x}, \boldsymbol{\beta})$. Considerando una proporción observada de éxitos dada por $p = y/m$, el valor esperado anterior se transforma en: $E(y/m | \mathbf{x}) = E(p | \mathbf{x}) = \pi(\mathbf{x}, \boldsymbol{\beta})$, lo cual sigue la línea de nuestra observación anterior.

²De acuerdo con los conceptos que venimos explorando, esto constituye el *enfoque dinámico*.

estimarse para luego evaluar modelos ajustados. Ello no obstante, y como los datos nunca se tienen antes de realizar el experimento, creemos que resultará útil hacer un estudio preliminar sobre la base de datos simulados computacionalmente.

En esta parte del trabajo proponemos un punto de vista conceptual y práctico sobre los principios generales que deberían considerarse para “calibrar” la familia de estrategias frente al problema de ajustar superficies de respuesta para datos binarios mediante simulaciones. Este proceso generador de datos quedará materializado en una superficie de respuesta concreta, o *superficie teórica*, que será el lugar geométrico en donde tengan sentido los valores esperados de los puntos de funcionamiento del proceso que estudiaremos. A partir del mismo, obtendremos los datos con los que evaluaremos los diseños para ajustar los modelos que comentamos.

Para estudiar superficies de respuesta para datos binarios, lo primero que debe hacerse es identificar un proceso cuyo comportamiento tenga esta característica de naturaleza binaria. A estos efectos, simularemos las observaciones de la respuesta computacionalmente utilizando las buenas prestaciones del programa **R**.

5.2. Consideraciones de la estrategia propuesta

Presentamos en esta sección un “mapa” general del estudio del tema que nos ocupa, que para hacerlo más práctico, hemos dividido en etapas sucesivas. Comentaremos seguidamente en qué consiste cada una de ellas de forma esquemática y en lo que queda del trabajo, nos ceñiremos a desarrollar cada una de ellas, al mismo tiempo que incluiremos detalles y observaciones a medida que vayan surgiendo en el desarrollo que llevamos a cabo.

5.2.1. Superficie teórica

Partimos de la situación que el experimentador que se encuentra frente a un sistema en el que se pretende maximizar una probabilidad de éxito de un proceso, para el cual tiene identificados ciertos factores de variabilidad que piensa que tienen influencia sobre aquella respuesta. Como comentamos anteriormente, dicho proceso estará representado mediante una superficie teórica, ST , que simularemos computacionalmente.

5.2.2. Presupuesto fijo

El escenario que hemos previsto para esta situación es aquél en que se ha dispuesto un *presupuesto fijo* para destinar a la experimentación, que se traducirá en un número máximo fijo de puntos experimentales que podrán observarse. Con toda la información que pueda obtenerse, definiremos ciertas medidas de la calidad de ajuste conseguida

luego de haber utilizado todos los puntos. Para ello, hemos basado nuestro estudio posterior a través de la consideración de un presupuesto definido por el costo asociado a $n = 1500$ puntos observacionales.

5.2.3. Respuesta

- Las respuestas provienen de un número fijo de procesos binomiales, cada uno consistente en m_i realizaciones de un proceso de Bernoulli en el cual interesa una característica llamada “éxito”, que ocurre con una probabilidad igual a π_i . La definición de esta característica de calidad “éxito” dependerá del proceso en estudio y de sus objetivos a seguir.
- Cada proceso binomial individual i quedará caracterizado por un conjunto particular de valores de un grupo de factores de variabilidad, \mathbf{x}_i , controlados por el experimentador, que definirá una condición experimental particular de la cual se observarán realizaciones del proceso binomial asociado. Así, en la i -ésima condición experimental, se habrán realizado m_i repeticiones del experimento de Bernoulli (éxito-no éxito) y se habrán obtenido y_i éxitos, cada uno de ellos, con probabilidad π_i . Supondremos asimismo que el número de éxitos obtenido en una condición experimental no aporta información para predecir los éxitos de cualquiera de las otras condiciones experimentales. Esto es: partiremos también de distribuciones independientes.
- La respuesta a estudiar será el valor esperado del número de éxitos obtenidos en cada condición experimental, que es igual a la probabilidad de éxito de la misma. Como respuesta “observada”, se tendrán las proporciones de éxitos conseguidas en cada una de las condiciones definidas, que es el estimador máximo verosímil de la probabilidad de éxito.

5.2.4. Factores y niveles

- Se establece un conjunto de $k = 2$ factores de variabilidad, de naturaleza fija, que tomarán valores de tal forma que cada uno de ellos identifique unívocamente una condición experimental, para la cual se realizarán varias observaciones del número de éxitos.
- Consideraremos que cada factor podrá tomar solamente dos valores: uno “bajo” y otro “alto”, cuya especificación dependerá de la naturaleza del factor (p. ej., y siguiendo la lógica de los diseños 2^k , un factor x_i puede llegar a tomar los niveles -1 y 1 para el caso en que se consideren unidades codificadas).

- La probabilidad de éxito —salvo que su verificación acuse lo contrario— se supone constante para una misma condición experimental y se la asociará a los factores y sus coeficientes mediante una cierta función $\pi(\mathbf{x}, \boldsymbol{\beta})$, que depende de los niveles considerados para los factores y de un conjunto de factores desconocidos.

5.2.5. Modelos

Utilizaremos el modelo logístico para enlazar el valor esperado de la respuesta con la función lineal de los factores, el predictor lineal, es decir:

$$E(y_i | \mathbf{x}_i) = \pi(\mathbf{x}_i, \boldsymbol{\beta}) = \frac{\exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})}{1 + \exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})}.$$

Cuando nos resulte conveniente, emplearemos la transformación logit del mismo. Como corolario natural, resulta que la transformación logit es de naturaleza monótona, diferenciable y creciente, con lo que las observaciones —en el sentido de “aspectos a observar”, no del de valores de una variable— que podamos realizar de la función $\pi(\mathbf{x}, \boldsymbol{\beta})$ serán análogas a las que puedan realizarse para el predictor lineal $\eta = \beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x}$.

5.2.6. Diseños factoriales y *MLG*

La utilización del modelo logístico —y su transformación logit asociada— permite cumplir los requisitos básicos impuestos para el empleo adecuado de los *MLG*:

- Se dispone de n observaciones independientes de la respuesta, que serán realizaciones de una cierta variable aleatoria “ $y_i =$ número de éxitos observados en la condición experimental i -ésima, cada uno de los cuales con probabilidad de éxito igual a π_i ”. En este sentido, se consideran m_i repeticiones del experimento de Bernoulli, cada uno con la misma probabilidad de éxito, llegándose a contar y_i éxitos en total, $0 \leq y_i \leq m_i$. Para nuestro estudio, mantendremos constante el valor de m , considerando en todos los casos un tamaño de observaciones de $m = 100$.
- La distribución binomial pertenece a la familia exponencial de distribuciones (ver **Apéndice B**).
- Los factores de variabilidad proporcionan un conjunto de predictores lineales $\eta = \beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x}$, para todas las condiciones experimentales.

5.2.7. Variables de estudio propuestas

Se trata de definir una estrategia de exploración para un proceso representado por una superficie de respuesta teórica, cuya respuesta tenga naturaleza de una proporción, para el cual hemos definido tres variables principales:

- *Factor de centro*, denotado por w , comprendido entre 0 y 1, que permite definir un plano paralelo al plano de los factores con el que se interseca a la superficie teórica. Dicha intersección define una curva de nivel —elíptica— la cual es utilizada para definir el primer centro de experimentación.
- *Lado del diseño*, denotado por L , que se definirá tomando al punto anteriormente definido como centro de un cierto diseño factorial rectangular, de lados proporcionales a L . Para simplificar esta primera aproximación, se tomarán factoriales que contengan superficies cuadradas, ambas con el mismo valor del lado.
- *Salto entre centros*, denotado por S , que llamaremos “salto”, que representará la longitud en valor absoluto que separa un centro de diseño del siguiente. A partir de los modelos ajustados, se calculan los cosenos directores de los correspondientes saltos.

5.2.8. Niveles para las variables de estudio

Para las variables de estudio propuestas, establecemos 5 niveles fijos para cada una de ellas. Mediante la definición de dos familias de selección de modelos ajustados —las cuales describiremos más adelante— se buscarán las mejores condiciones operativas del proceso. En los puntos siguientes, explicaremos esta secuencia paso a paso.

5.2.9. Objetivo

Partiendo de una superficie de respuesta que sea la que mejor se considera que se aproxima a un proceso real, el objetivo será el de encontrar los niveles de las 3 variables de estudio propuestas, w , L y S , que alcancen los mejores valores posibles de las dos familias de criterios de selección de modelos que explicaremos seguidamente. Dichos niveles encontrados, representarán los “mejores” valores de la probabilidad de éxito dentro de las regiones consideradas.

5.2.10. Etapas de estudio

En el desarrollo de nuestra estrategia, formada por las 3 variables de estudio, w , L y S , dividiremos nuestra evaluación de estrategias en 4 etapas consecutivas, que facilitarán la exploración sistemática de los casos a analizar.

Etapa I: todas las variables fijas para 1 caso

Inicialmente, y como hemos comentado anteriormente, partiremos de un primer caso de estudio en el que dispondremos de un presupuesto fijo de 1500 puntos experimentales tipo Bernoulli, que se pueden expresar también como una sucesión de 3 diseños de 5 puntos binomiales, cada uno contabilizando el número de éxitos provenientes de 100 experimentos de Bernoulli³. Al conjunto de estos 15 puntos binomiales (ó 1500 de Bernoulli) lo identificaremos como un “caso” o, siguiendo la nomenclatura que utiliza el programa **R**, un “data frame” de puntos. Como punto de partida, también tomamos un valor fijo⁴ para el Factor de centro, w , como así también para las otras variables, L y S .

Como veremos más adelante, a partir de la definición del Factor de centro w , estaremos en condiciones de proponer una forma de establecer la localización del primer centro de experimentación. Mediante la consideración del valor elegido para el lado del diseño, L , se podrá estudiar un primer diseño que permita ajustar un modelo con los 5 puntos de diseño recientemente descritos: el central y los 4 que componen el factorial.

Una vez que se ha ajustado el primer modelo con los 5 puntos del primer diseño, se determina con los coeficientes estimados del mismo la dirección de máximo crecimiento de la respuesta, o “steepest path”. Pero *¿cuánto* habrá que moverse hacia un nuevo conjunto de puntos una vez definido este gradiente? Ante esta cuestión, es que tomamos en consideración la tercera variable, S , que medirá el valor absoluto del “salto” en la dirección y sentido del gradiente.

Etapa II: todas las variables fijas para 15 casos

En esta segunda etapa, se hace exactamente lo mismo que en la anterior, partiendo de los mismos valores de las 3 variables. Al tener w el mismo valor en todos los casos, el primer centro será el mismo. Lo mismo aplica con el lado del factorial, L . Sin embargo, es de esperar que la generación de éxitos correspondiente a cada punto de diseño ya no sea la misma que en el caso anterior, lo cual definirá un modelo ajustado distinto al primero y a su vez, un gradiente distinto. Si bien se mantiene el valor adoptado para S , ya su dirección no será entonces la misma. De este modo, se obtendrá un segundo centro distinto al del primer caso, lo mismo que un tercer centro.

Si repetimos esta idea unas 15 veces en total, tendremos 15 casos distintos de secuencias de diseños factoriales a dos niveles y evaluados en los mismos 3 valores

³Sin embargo, esta es solamente una de las posibilidades disponibles. Cuando abordemos el capítulo de conclusiones, haremos referencia a las extensiones de estudio que pueden realizarse teniendo en cuenta este esquema de partida.

⁴En el capítulo 8 damos una justificación acerca de la elección de los niveles para estas tres variables de estudio propuestas.

de las variables de estudio. Los mismos constituyen 15 cuadros de puntos. La idea principal de esta replicación es que al evaluar el ajuste de los 15 modelos finales obtenidos respectivamente, se reduzca la variabilidad de los estadísticos con los que mediremos la calidad de ajuste de los mismos.

Etapas III: L y S variables, para w fija

Anteriormente, comentamos que nuestro estudio comenzaba con la elección de un valor fijo para L y para S . En esta etapa, no tendremos en cuenta 1 sino 5 niveles tanto para L como para S , aunque seguiremos con el mismo valor fijo tomado para w que en la etapa anterior. Con todos estos niveles considerados para ambas variables formamos una matriz —que dimos en llamar *matriz LS*— que comprenderá las $5 \times 5 = 25$ posibilidades de combinación de los niveles de estas dos variables para un mismo valor de w . Todo este esquema de niveles corresponde a una sola “corrida” de las 15 que definimos en la etapa anterior.

Con el mismo esquema que seguimos en las etapas I y II, evaluamos aquí los 15 cuadros de puntos en cada una de los 25 casos que define la matriz **LS**. El único aspecto que tendrán en común tanto diseños de puntos como modelos finales ajustados, es que al ser constante la variable w , todas las exploraciones secuenciales partirán del mismo punto inicial.

Etapas IV: L , S y w , todas variables

Finalmente, y de forma análoga a como hicimos en la etapa anterior, tomando los mismos 5 niveles para cada una de las variables L y S , aquí consideraremos otros 5 niveles para la variable restante, w . Por simplicidad, tomaremos el siguiente vector de niveles:

$$w = \{0,50; 0,10; 0,15; 0,20; 0,25\} \times 100\%$$

Resulta bastante directo encontrar que cada nivel de w definirá una posición inicial distinta para el primer centro de experimentación. Asociado este hecho con la consideración de los 15 cuadros de puntos, evaluados a su vez en las 25 condiciones dadas por las filas de la matriz, nos queda planteado un problema interesante, que en definitiva será el que define el objetivo de nuestro estudio: *habiendo definido criterios de evaluación determinados para las estrategias de exploración, nos centraremos en encontrar qué valores de las 3 variables hacen que se obtengan los mejores valores de los estadísticos correspondientes, los cuales redundarán en una mejor aproximación de la ST a través del modelo ajustado.*

5.2.11. Evaluación de estrategias

Para poder evaluar de manera objetiva qué estrategia seguida es la que ha dado mejores resultados, hemos definido dos criterios de los cuales nos valdremos para elegir qué modelo ajustado es el que mejor nos sirve para alcanzar nuestro objetivo. La información que proporcionen los modelos ajustados para cada caso evaluado, junto con todos los puntos de diseño considerados a lo largo de toda la experimentación, permitirán calcular básicamente dos estadísticos y compararlos homológamente.

Los dos criterios definidos se basan en estadísticos calculados con toda la información que ha proporcionado la utilización de todo el presupuesto disponible. Cada uno de ellos, define un criterio propio de evaluación de bondad de ajuste, que definimos a continuación:

Criterio I: cantidad de información

Partiendo de primer centro de experimentación —definido por w —, de un par de valores⁵, uno para el lado del diseño, L , y otro para el salto, S , esta estrategia consiste en diseñar factoriales a dos niveles en etapas sucesivas y ajustar modelos logísticos con todos los puntos observados hasta la última etapa. Considerando el modelo completo, es decir, con todos los términos del último modelo ajustado, se calcula el determinante de la Matriz de Información de Fisher, que abreviaremos de aquí en más como MIF , que será:

$$\det(\mathbf{I}_F) = \det(\mathbf{X}'\mathbf{W}\mathbf{X})$$

En nuestro estudio, consideraremos el cálculo de los determinantes de las MIF teniendo en cuenta ambos casos, como así también los logaritmos de los mismos, teniendo como objetivo encontrar qué modelo es el que maximiza esta cantidad, que será el mismo que minimice la matriz de varianzas y covarianzas de los coeficientes del modelo.

Criterio II: proximidad al máximo

El otro estadístico que definimos para evaluar la calidad del modelo ajustado toma como punto de partida el punto $\hat{\mathbf{x}}_{\text{máx}}$ que corresponde al máximo valor del modelo ajustado en el plano de los factores. Evaluando dicho punto en el modelo teórico, $\pi(\hat{\mathbf{x}}_{\text{máx}}, \boldsymbol{\beta})$, tendremos una idea de cuánto nos hemos aproximado a las mejores condiciones “teóricas”, valor dado por $\pi(\mathbf{x}_{\text{máx}}, \boldsymbol{\beta})$. En la figura 5.1 representamos esquemáticamente este estadístico para el caso de un solo factor:

⁵Partiremos de la evaluación de 5 niveles tanto para L como para S , configurándose así una matriz \mathbf{LS} formada por una “rejilla” formada por 25 valores.

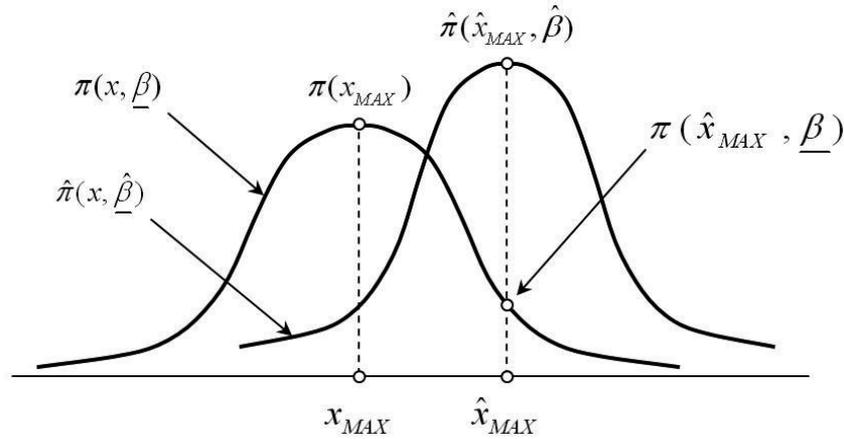


Figura 5.1: Definición del estadístico $\pi(\hat{x}_{m\acute{a}x}, \underline{\beta})$ como medida de calidad del ajuste.

En la misma figura 5.1 podemos distinguir dos modelos: el teórico y el ajustado que se ha conseguido al haber agotado todo el presupuesto disponible, representados por $\pi(x, \underline{\beta})$ y $\hat{\pi}(x, \hat{\underline{\beta}})$, respectivamente. Para el caso del modelo ajustado, su punto máximo estará dado por $\hat{\pi}(x_{m\acute{a}x}, \hat{\underline{\beta}})$, cuya abscisa será el punto $\hat{x}_{m\acute{a}x}$. Este punto se puede considerar como el que le informa al experimentador de las mejores condiciones que se han podido conseguir luego de ajustar el modelo. Pero como ese punto tiene naturaleza aleatoria, utilizarlo como medida de bondad de ajuste podría no resultar muy claro. Para ello, si lo evaluamos en un modelo menos variable como por ejemplo el teórico, tendremos una idea más clara de cuánto se ha conseguido mejorar el proceso mediante su comparación con el valor máximo del modelo teórico.

Nota bene: queda claro que, de acuerdo con lo que venimos explicando, la progresión en el proceso de evaluación de ambos criterios sigue las 4 etapas definidas anteriormente: (a) todas las variables fijas para 1 caso; (b) todas las variables fijas para 15 casos; (c) w fijo y L y S variables para los 15 casos, y (d) L , S y w variables para los 15 casos.

5.3. Desarrollo de las estrategias

Para organizar mejor el desarrollo de estas estrategias, hemos organizado nuestro estudio de acuerdo a los contenidos de los próximos 2 capítulos, agrupando sus temas de acuerdo con el siguiente esquema:

- Desarrollos: primera parte (**Capítulo 6**)
- Desarrollos: segunda parte (**Capítulo 7**)

A continuación, damos un breve panorama de los contenidos de cada una de éstas, que estudiaremos detenidamente en los respectivos capítulos para el caso particular de un proceso generado computacionalmente.

5.3.1. Desarrollos: primera parte

El primer paso que es necesario dar será de alguna manera especulativo: diremos que el proceso que pretendemos explorar es susceptible de ser representado mediante una ST . Para ello, supondremos que a través de la integración de otras fuentes de conocimiento tanto estadístico como no estadístico, hemos podido establecer un cierto modelo como “adecuado”, es decir, de una ST en la que supondremos un valor para el vector de parámetros β .

Nuestro estudio se enmarca en la consideración de ST generadas por $k = 2$ factores, x_1 y x_2 , los cuales supondremos de naturaleza continua, que también supondremos que se han determinado en ausencia de error. Como caso más global, nos centraremos en las superficies que provengan del modelo más genérico para esta configuración de factores, que será el *modelo completo de segundo orden*, que comprenderá tanto los términos de primer orden en los factores como los de segundo (incluyendo los cuadráticos y la interacción de los efectos principales). Esta indicación nos lleva a considerar un cierto vector de parámetros del modelo, β , con $p = 6$ parámetros, definido por:

$$\beta = (\beta_0, \beta_1, \beta_2, \beta_{11}, \beta_{22}, \beta_{12})'$$

Al considerar el modelo logístico, la ST estará dada por expresiones como la (5.1):

$$\pi(\mathbf{x}, \beta) = \frac{\exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})}{1 + \exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})}, \quad (5.1)$$

$$0 < \frac{\exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})}{1 + \exp(\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x})} < 1, \quad (5.2)$$

en donde:

$$\beta_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2$$

constituye el predictor lineal —completo de segundo orden— del modelo correspondiente.

Dado que la función $\pi(\mathbf{x}, \beta)$ dependerá de los valores que tome el vector de parámetros β , asignaremos a cada uno de ellos un vector de niveles, según el cual, cada β_j

considerado en el modelo dado por la ecuación (5.1) podrá tomar 3 posibles valores, que en términos generales diremos que serán: $-a$, 0 y a , siendo a un escalar cualquiera. Para hacer sistemático el estudio y comparar resultados, se partirá de una sola configuración del vector de parámetros, si bien la flexibilidad del programa **R** permite evaluar múltiples configuraciones de aquél vector.

Habiendo definido estos 3 posibles niveles que pudiera tomar cada uno de los $p = 6$ parámetros del modelo, es posible considerar todas las posibles configuraciones de parámetros que podría llegar a tomar la superficie teórica. Así encontramos que se podrán considerar $3^6 = 729$ modelos o configuraciones posibles del vector β . La utilización del programa **R** nos resultará de gran utilidad para la generación y tratamiento de cada una de las familias de modelos simulados, que quedarán materializadas mediante las matrices de los modelos asociados, de 729 filas \times 6 columnas, cada una de ellas correspondiente a la asignación de los tres niveles posibles a cada uno de los coeficientes β_j considerados en el mismo modelo.

Disponiendo ya de una tabla de modelos disponibles para una configuración del vector β como describimos en la subsección anterior, el experimentador elegirá la fila que juzgue que mejor representa a su proceso, es decir, un modelo teórico materializado por un cierto vector,

$$\beta = (\beta_0, \beta_1, \beta_2, \beta_{11}, \beta_{22}, \beta_{12})'$$

el cual definirá la ST que generará las observaciones del proceso que estudiaremos. El paso siguiente será el del *diseño* en el estricto sentido estadístico: *determinar la localización de los puntos de diseño de tal modo de obtener la máxima información del proceso real, asociado al menor esfuerzo experimental*⁶.

5.3.2. Desarrollos: segunda parte

Siguiendo la misma tónica que en el esquema propuesto para el **Capítulo 6**, en el siguiente ampliaremos nuestro estudio de 1 a 15 casos generados aleatoriamente para la misma estructura de estudio: una terna de valores fijos para w , L y S , que a su vez corresponde con lo que llamamos “Etapa II” de las etapas de estudio.

Finalmente, para los **Capítulos 8** y **9**, dejaremos el estudio de la consideración de los 5 niveles para cada una de las mismas variables, luego de lo cual, ensayaremos nuestras conclusiones acerca de lo que hemos podido aprender en el desarrollo de esta estrategia propuesta de experimentación.

⁶En el caso de la estrategia de “presupuesto fijo” que hemos elegido, esta minimización de esfuerzo experimental se adapta al número de puntos experimentales disponibles, claro está.