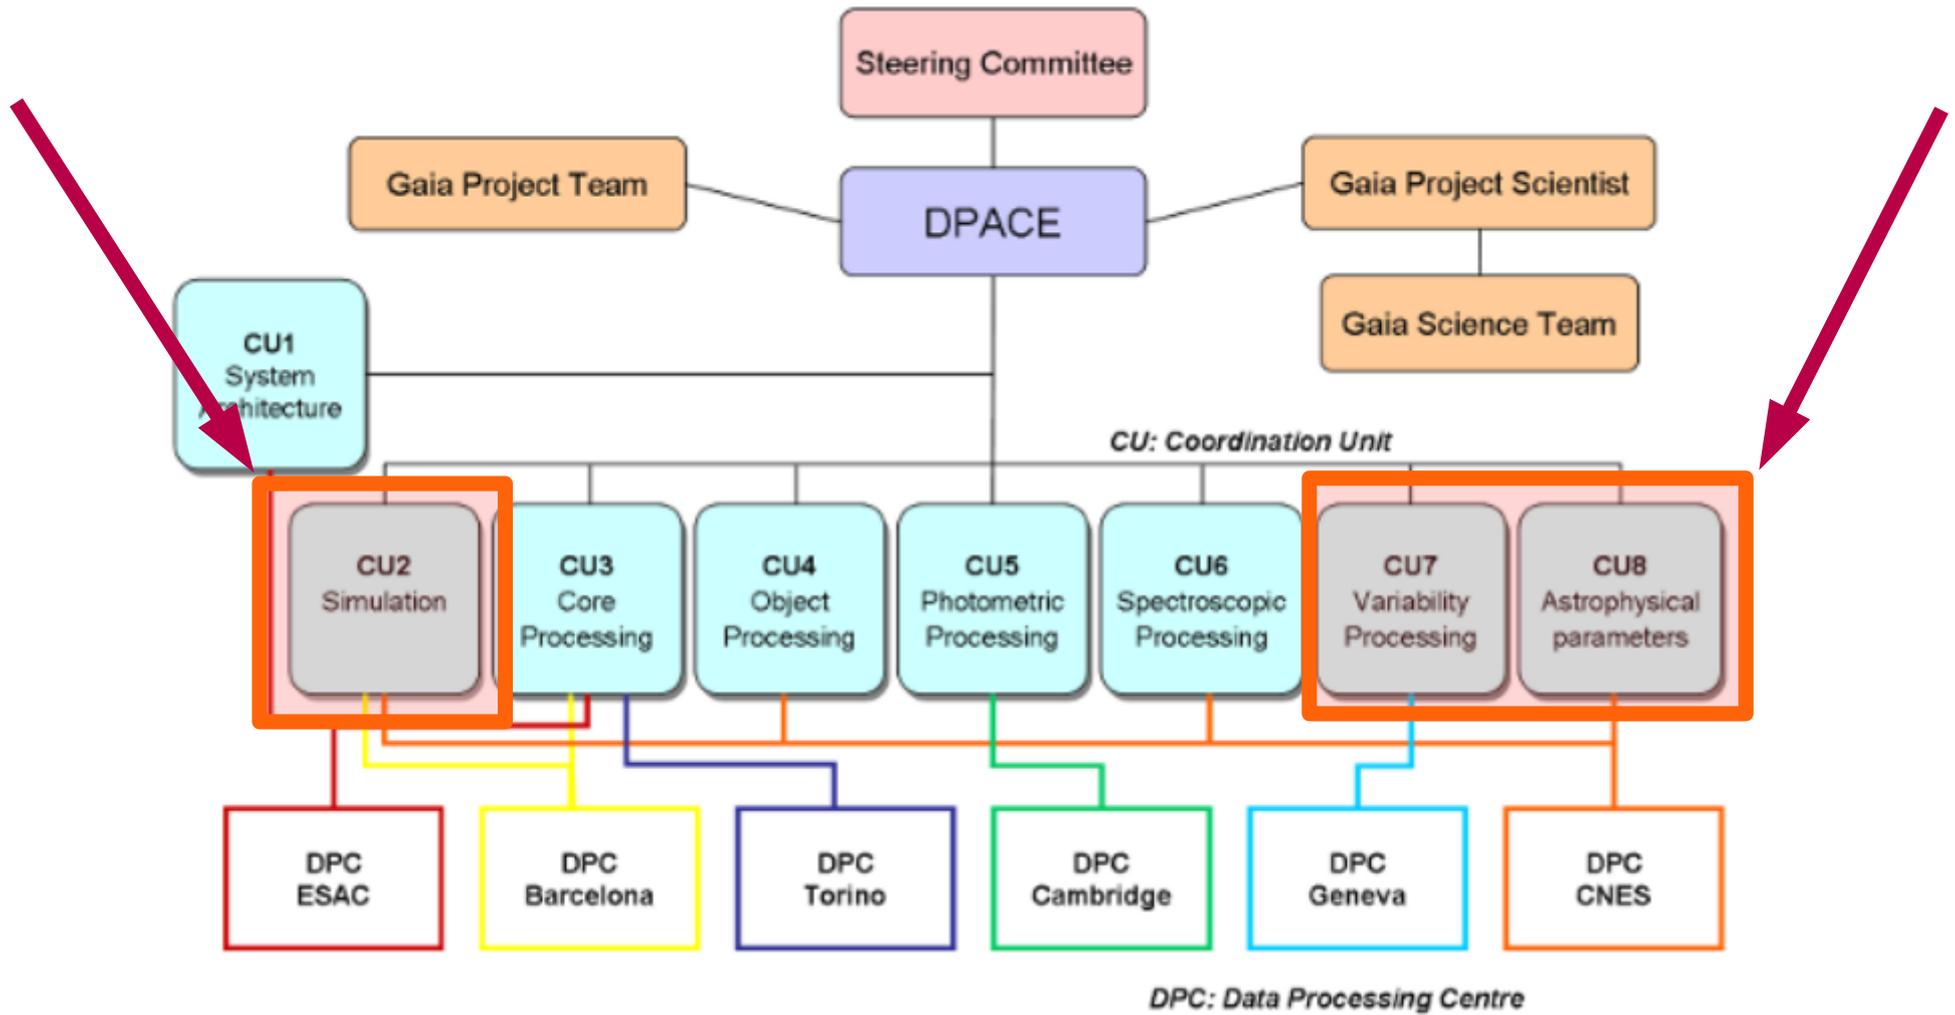


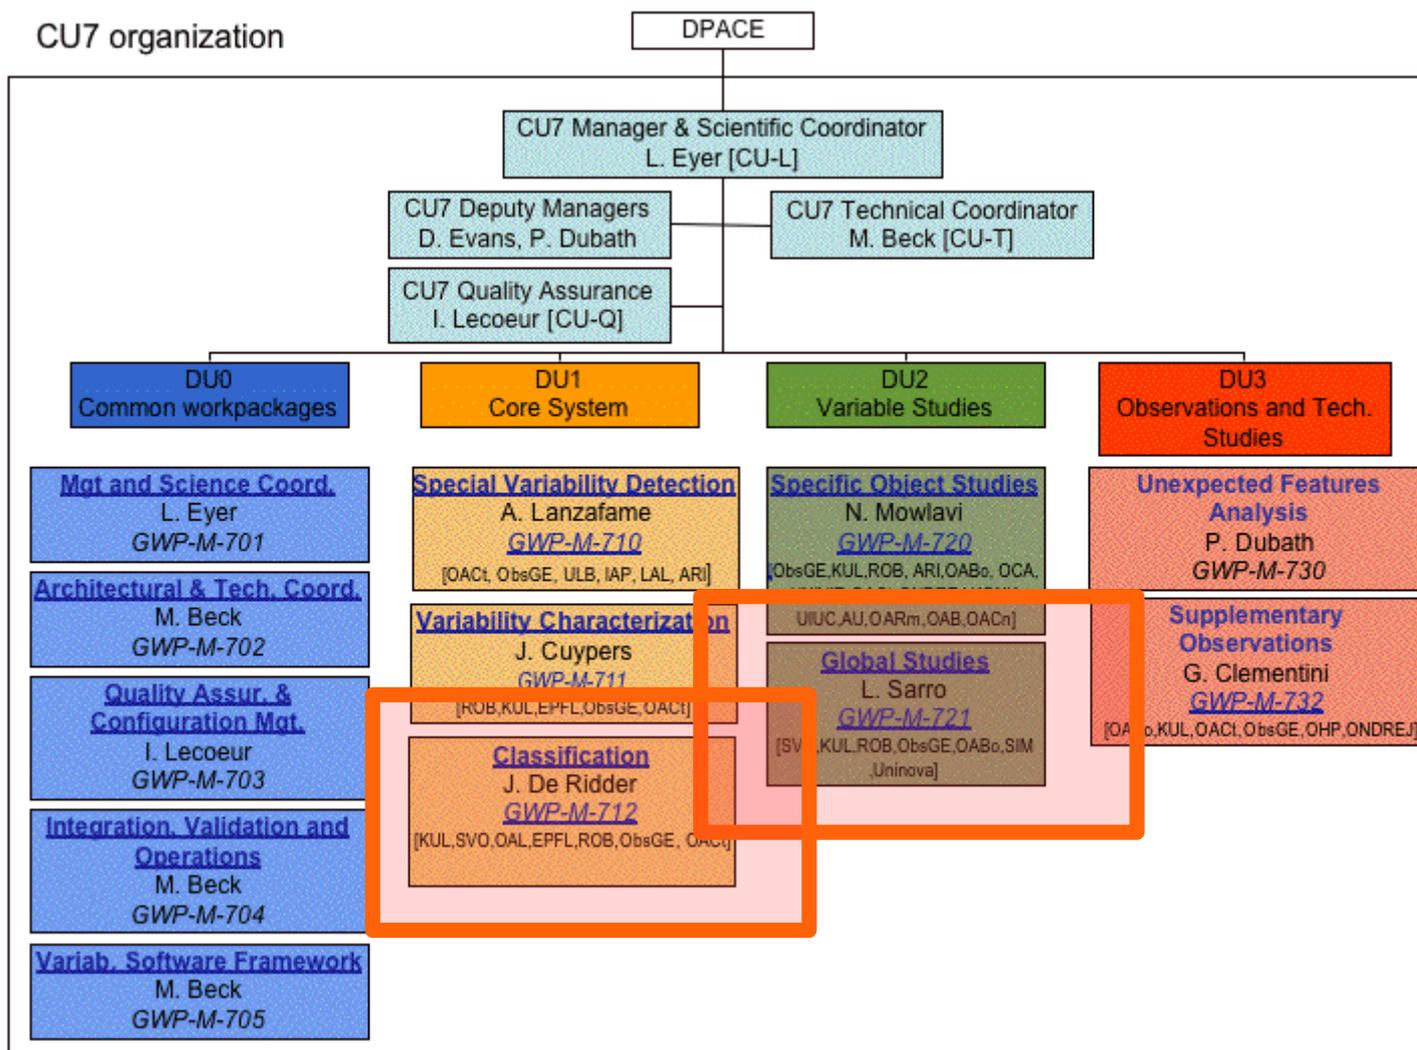
Minería de Datos y Astroestadística: Perspectivas futuras

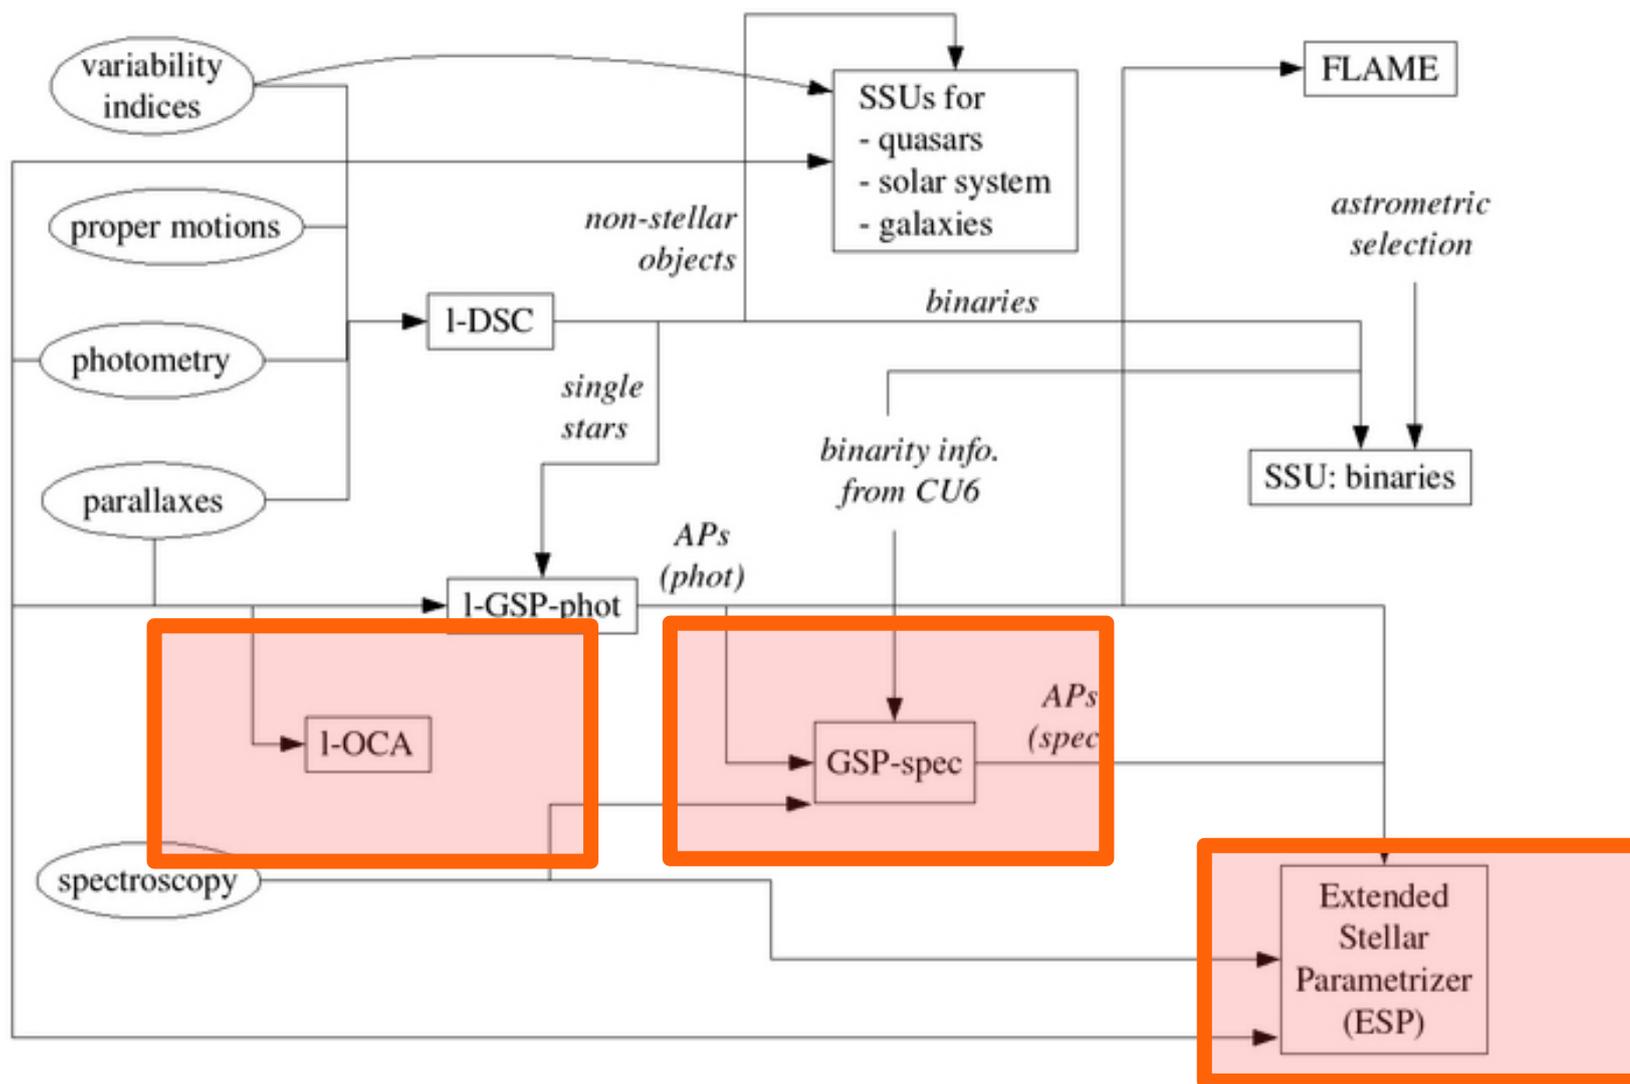
Luis M. Sarro – Dpt. Inteligencia Artificial (UNED)

- 1.- Implicación española en el Gaia DPAC
- 2.- Gaia-ESO survey
- 3.- Modelos jerárquicos









Desarrollos:

- 1.- Clasificación supervisada
- 2.- Predicción de parámetros físicos
- 3.- Detección de objetos exóticos y nuevas clases (clasificación no supervisada)
- 4.- Control de calidad



WG9 Clasificación espectral

WG10 Determinación de parámetros físicos

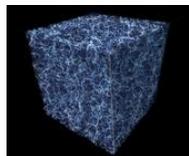
- FERRE
- MATISSE
- BIQUINI

WG12 PMS?

WG13 OBA?



Congreso/Escuela de Astroestadística y Minería de Datos



gaia

II Reunión científica de la Red Española para la explotación científica de Gaia –
Santillana del Mar, Septiembre de 2011

Dos problemas centrales en la explotación científica de Gaia:

1. Determinar para una fuente observada (conjunto de datos D) sus parámetros físicos ω
2. Determinar, para un conjunto de fuentes (muestra), las distribuciones estadísticas (población $p(\{\omega_j\})$) que generaron la muestra.

Ejemplos:

[1]

Parámetros físicos: T_{eff} , $\log g$, $[M/H]$, A_v , P , ...

Membresía a grupo móvil, población, cúmulo...

[2]

La función inicial de masas

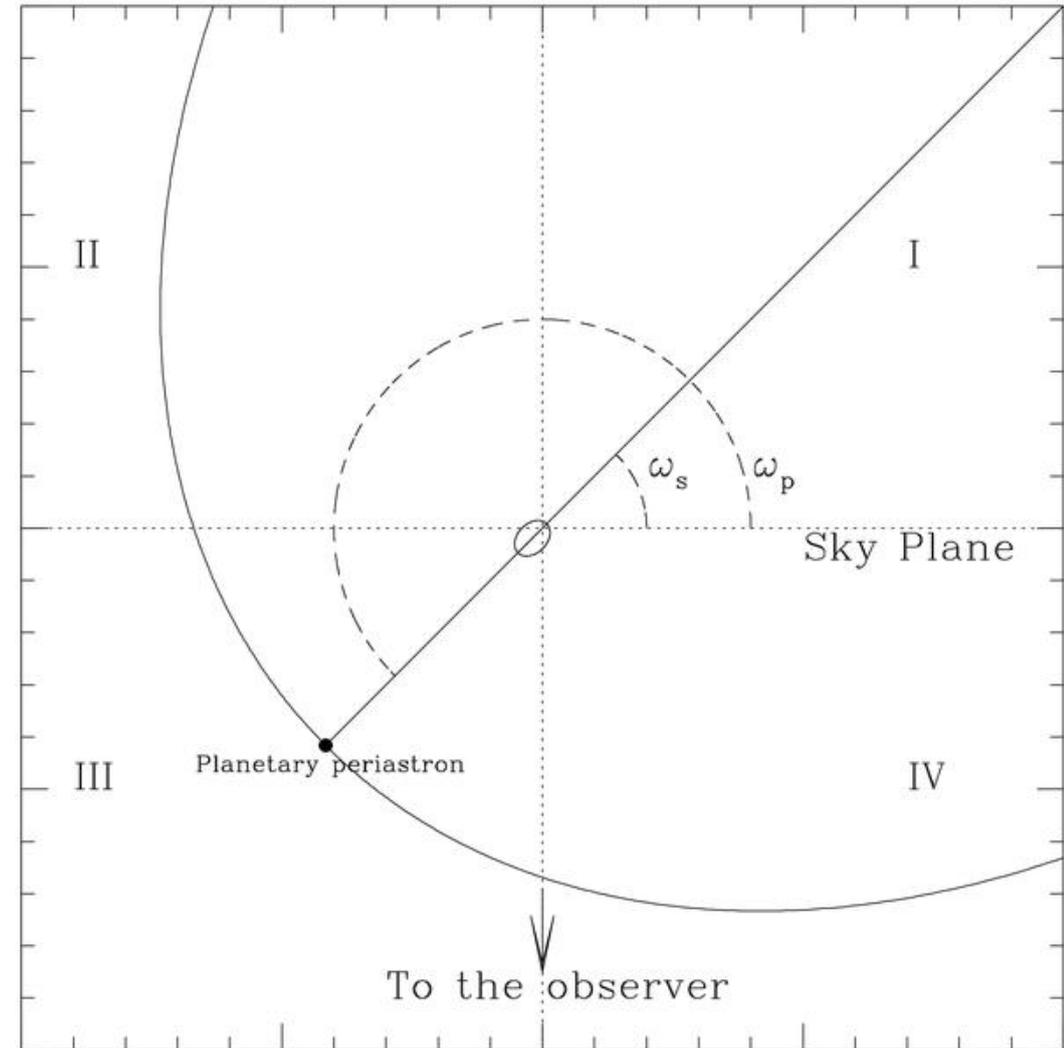
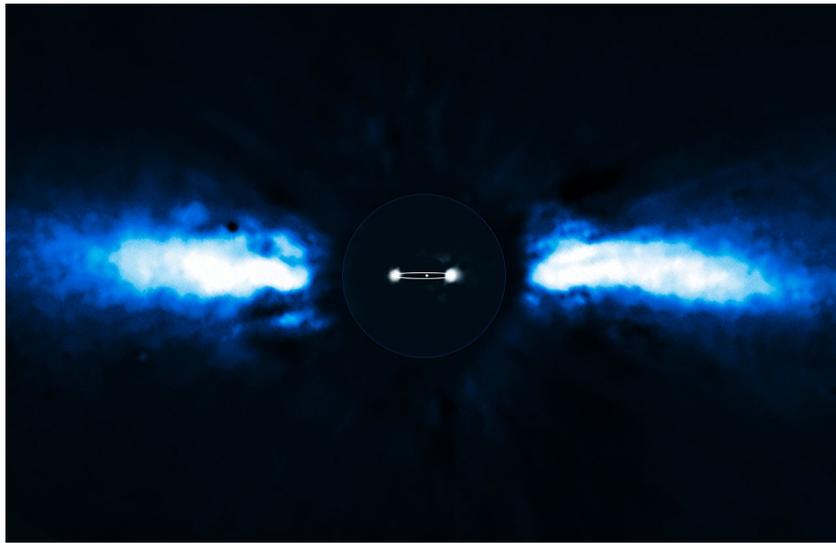
La tasa de formación estelar

Los parámetros que definen la barra, el bulbo, un grupo móvil...



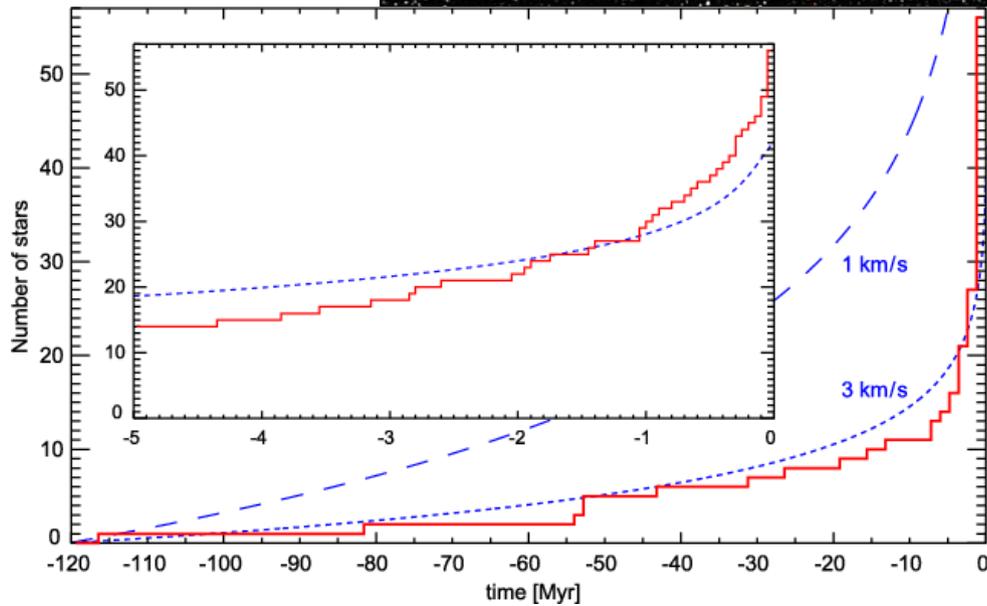
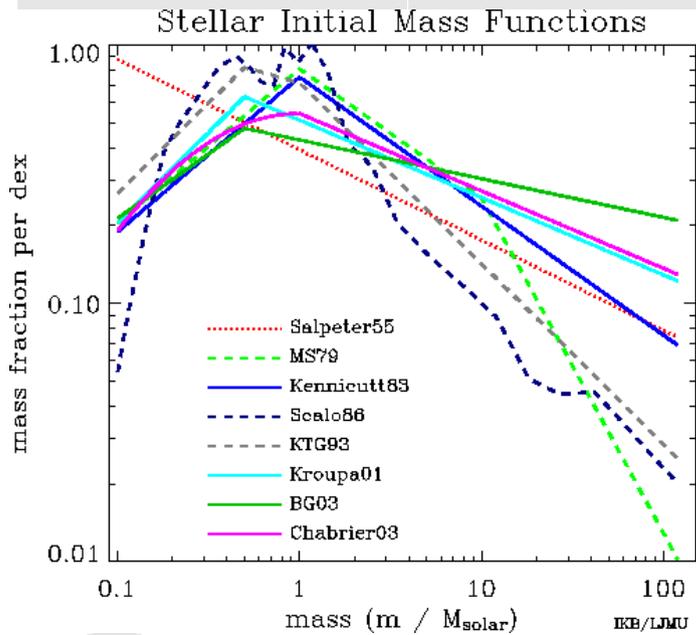
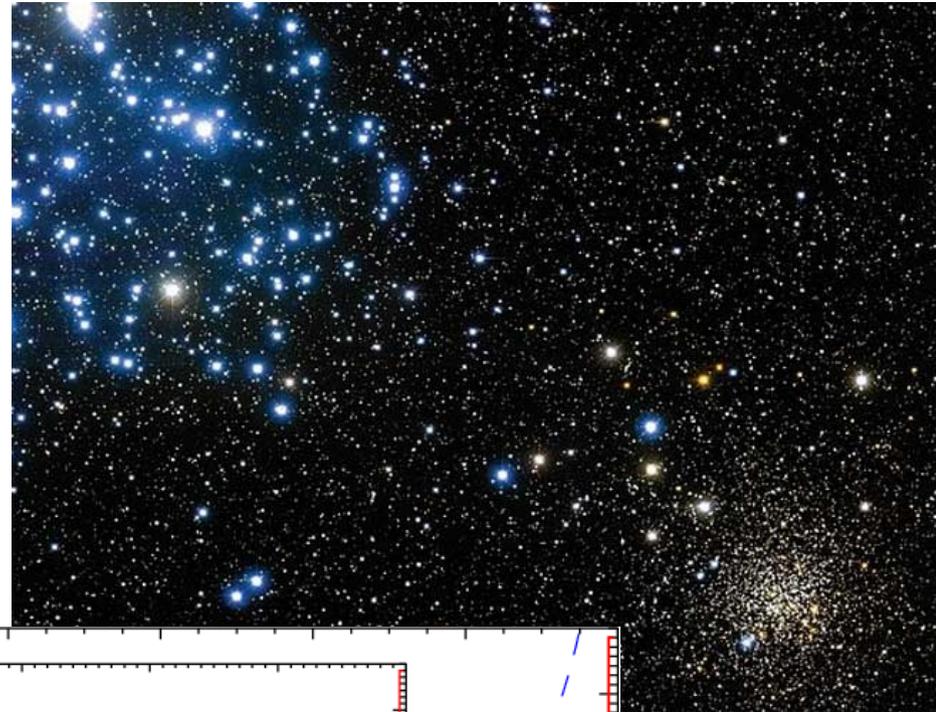
Modelos jerárquicos

	Ejemplo 1
Fuente	Estrella+exoplaneta
Datos ($\{D_i\}$)	$V_r(t)$
Parámetros físicos ($\{\omega_j\}$)	$e, T, \omega, \varphi, \kappa, i$
Distribuciones	IEF (Función Inicial de Excentricidades)= $p(e)$



Modelos jerárquicos

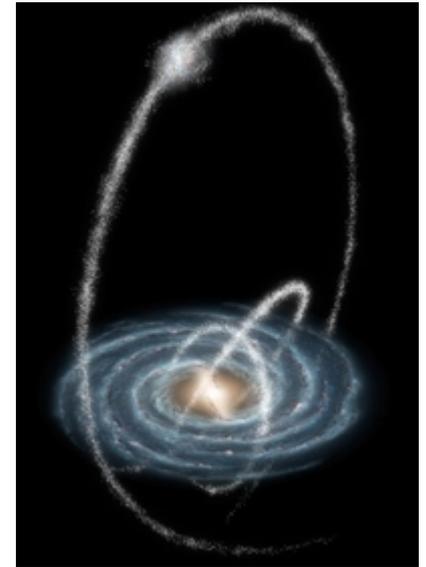
	Ejemplo 2
Fuente	Estrella en cúmulo
Datos ($\{D_i\}$)	BP/RP, astrometría, RVS
Parámetros físicos ($\{\omega_i\}$)	Probabilidad de pertenencia al cúmulo y parámetros físicos
Distribuciones	IMF, SRF



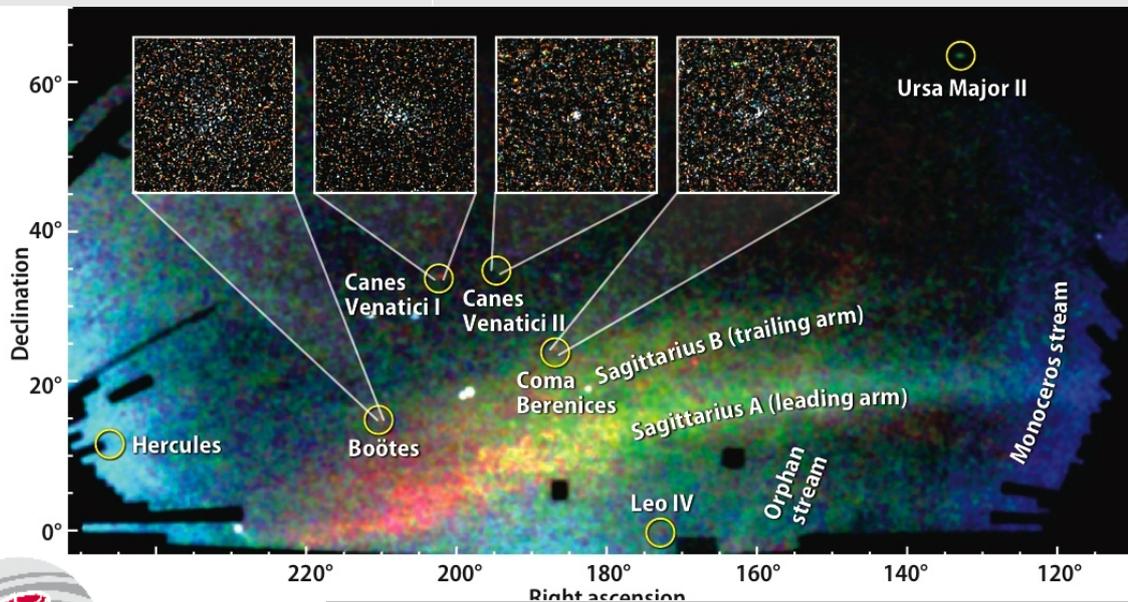
gaia

II Reunión científica de la Red Española para la explotación científica de Gaia – Santillana del Mar, Septiembre de 2011

Modelos jerárquicos

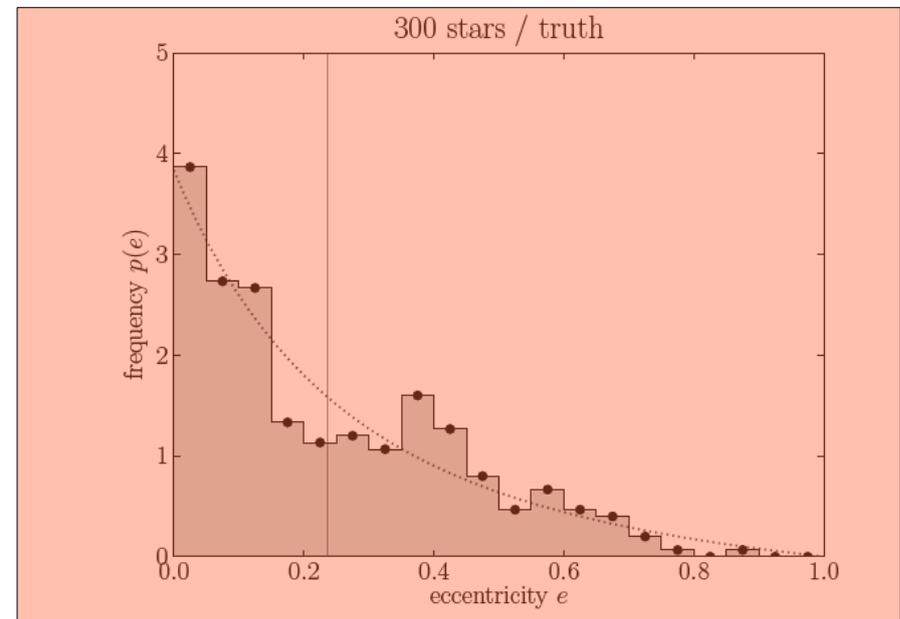
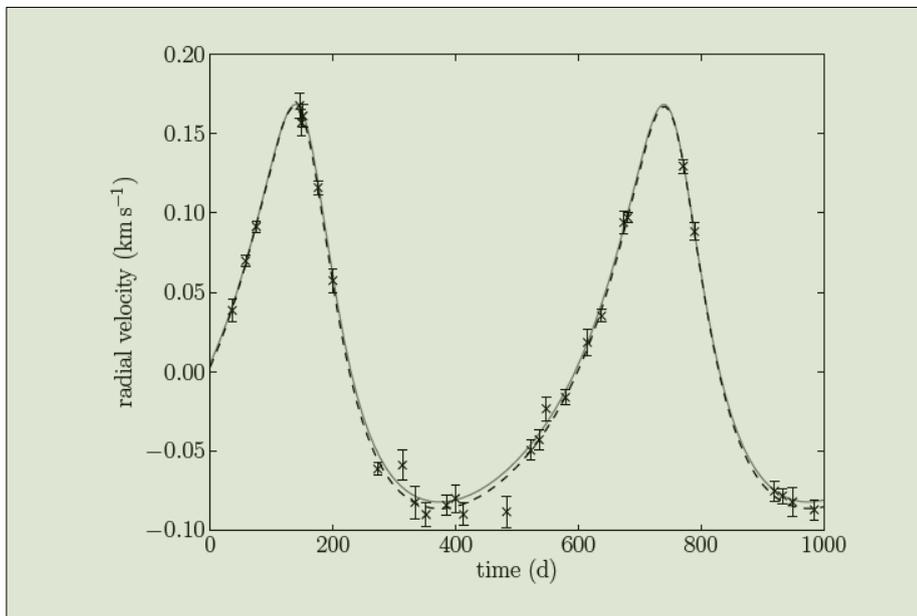


	Ejemplo 3
Fuente	Estrella Galaxia
Datos ($\{D_i\}$)	Astrometría, BP/RP, RVS, espectro alta resolución
Parámetros físicos ($\{\omega_i\}$)	Temperaturas, gravedades, metalicidades, edades...
Distribuciones	IMF(t,r), episodios de fusión, $\Omega(t,r)$, componentes de la Galaxia, número y distribución



La inferencia Bayesiana clásica procede a inferir los parámetros (ω) a partir la **verosimilitud** y del conocimiento **a priori**:

$$p(\omega|\mathbf{D}) = \frac{p(\mathbf{D}|\omega) \cdot p(\omega)}{p(\mathbf{D})}$$



Modelos jerárquicos

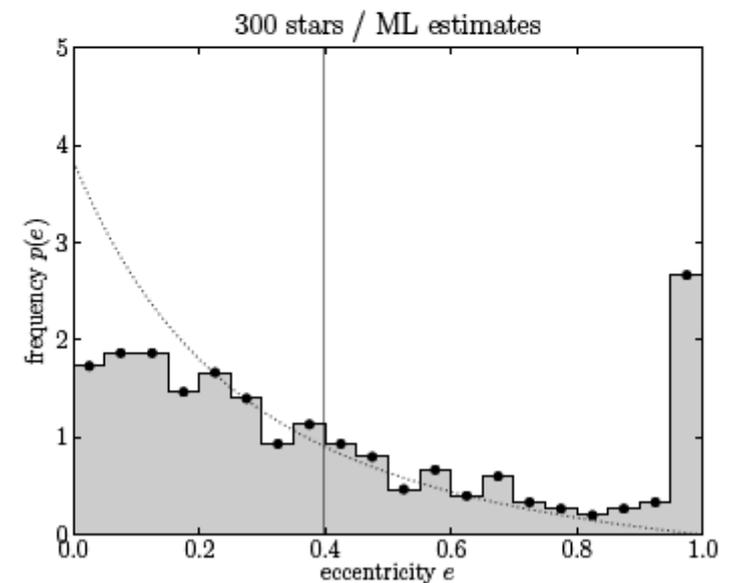
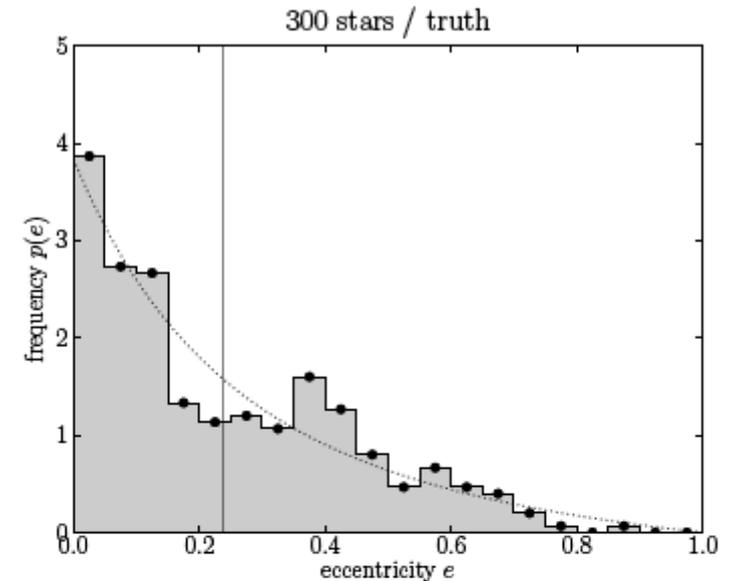
Supongamos que no estamos tan interesados en las propiedades particulares de un sistema estelar, sino en la distribución de una o varias propiedades (posiblemente en función de algún parámetro)

≡ **Análisis estadístico**

Alternativa 1: Obtenemos una estimación para cada uno de los sistemas de estudio y elaboramos un histograma o pdf equivalente.

Problema: los estimadores puntuales no sesgados son muy escasos. Máxima verosimilitud, MAP o las medianas de muestreos no lo son en general.

Además, no propagamos las incertidumbres.



Análisis estadístico

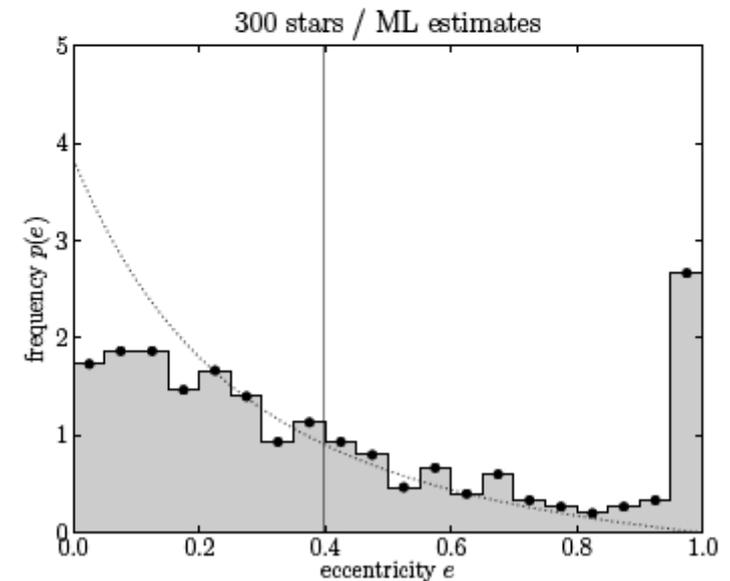
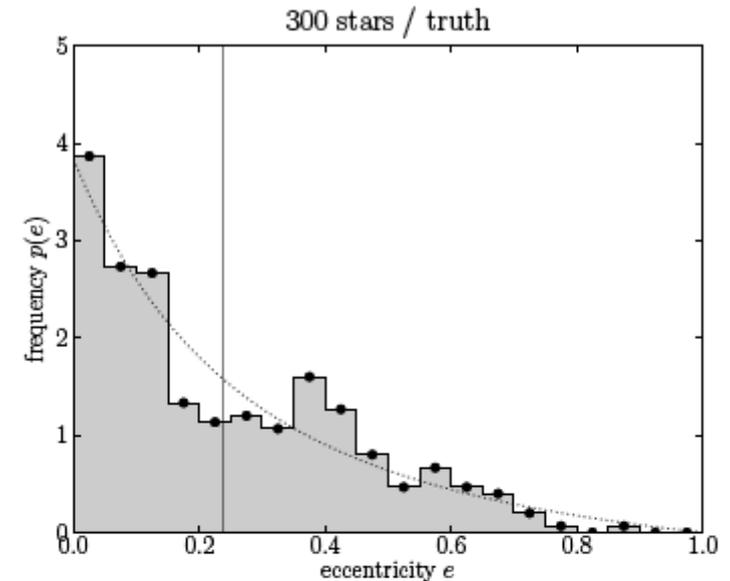
Alternativa 2:

Asumir que la distribución observada es el resultado de convolucionar la distribución real con las incertidumbres.

Implica modelar **de forma general** la relación entre los parámetros reales y los observados.

No utiliza las incertidumbres reales de las observaciones.

Es poco robusto.

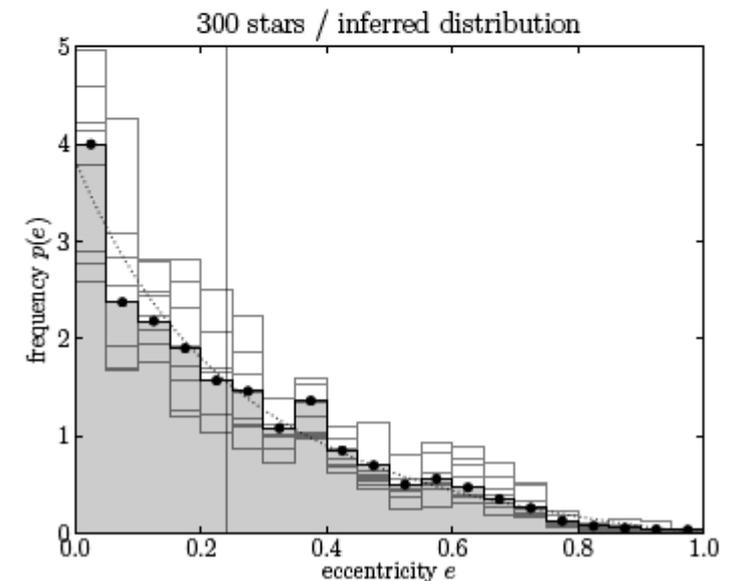
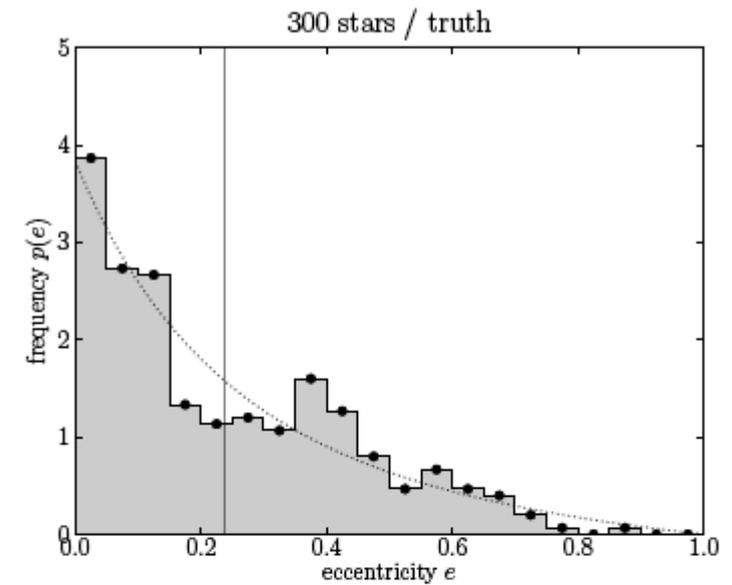


Alternativa 3: Proponer un modelo parametrizado por un vector α e inferir la distribución a posteriori de α

$$p(\alpha|\mathbf{D}) = \frac{p(\mathbf{D}|\alpha) \cdot p(\alpha)}{p(\mathbf{D})}$$

$$p(\mathbf{D}|\alpha) = \int p(\mathbf{D}|\omega) \cdot p(\omega|\alpha) d\omega$$

Recordad, \mathbf{D} siguen siendo los datos (por ejemplo, un espectro o la curva de velocidad radial)



$$p(\omega|\mathbf{D}) = \frac{p(\mathbf{D}|\omega) \cdot p(\omega)}{p(\mathbf{D})}$$

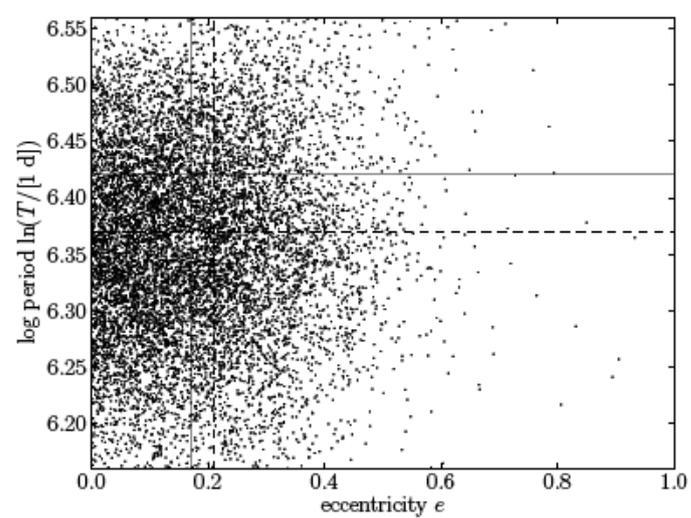
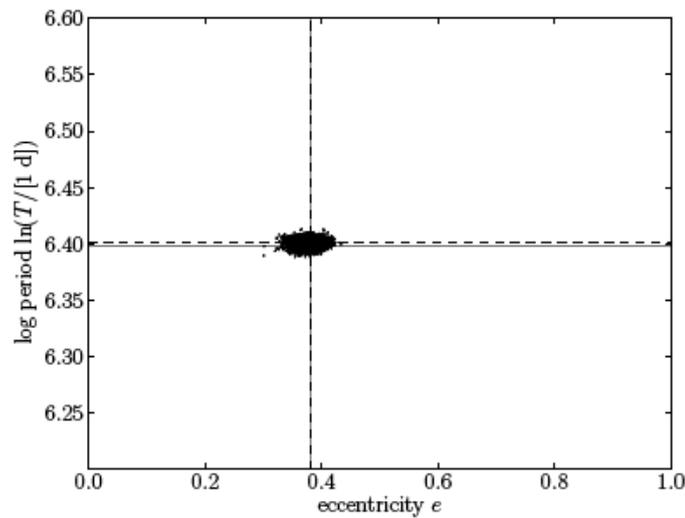
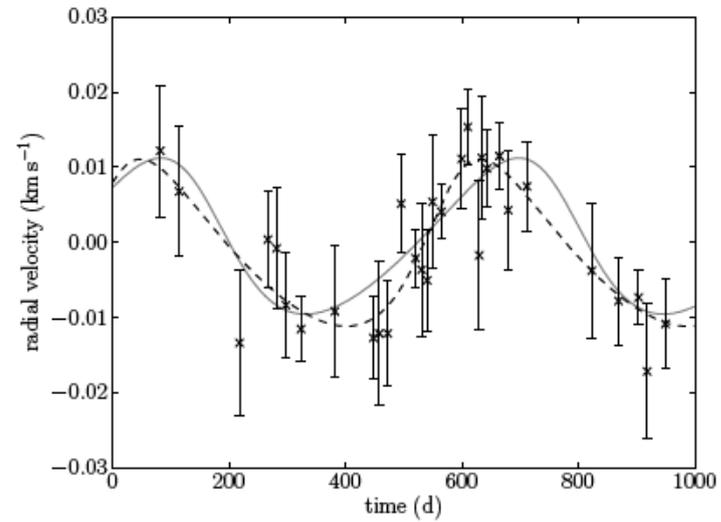
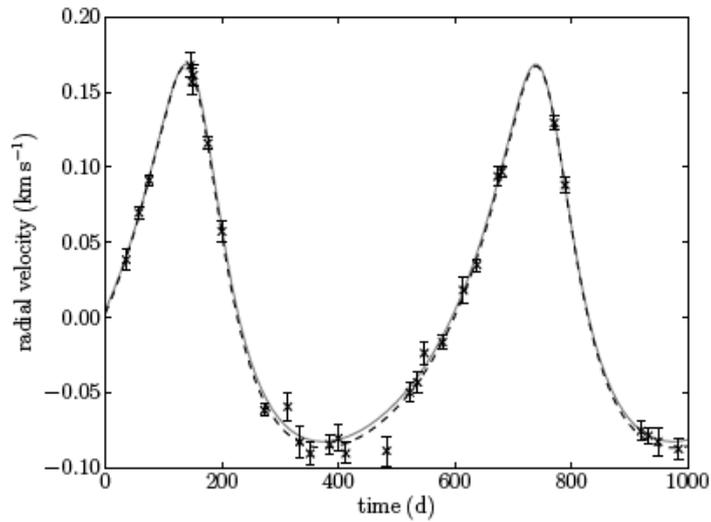
En espacios de muy alta dimensionalidad, hay que evaluar la verosimilitud en un número muy elevado de puntos.

Ejemplo: en astrosismología, hay que elaborar un modelo estelar para cada conjunto de parámetros (T_{eff} , t , $[\text{Fe}/\text{H}]$,...). Si tenemos 5 dimensiones y 10 puntos por eje hay que evaluar la verosimilitud en 10^5 puntos.

Soluciones: Sampling y forward modelling.



Sampling:

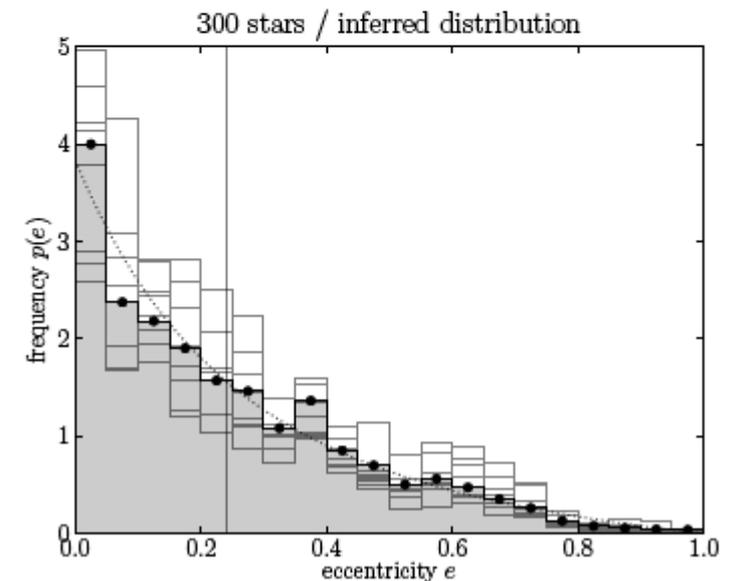
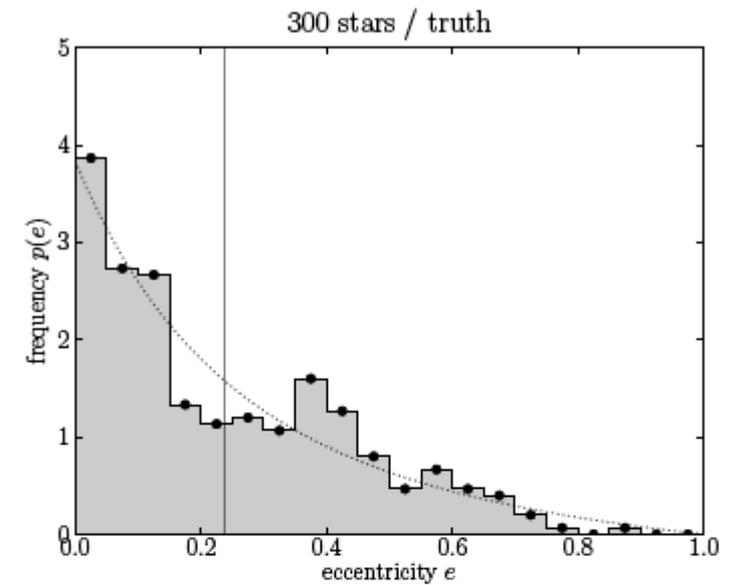


Alternativa 3: Proponer un modelo parametrizado por un vector α e inferir la distribución a posteriori de α

$$p(\alpha|\mathbf{D}) = \frac{p(\mathbf{D}|\alpha) \cdot p(\alpha)}{p(\mathbf{D})}$$

$$p(\mathbf{D}|\alpha) = \int p(\mathbf{D}|\omega) \cdot p(\omega|\alpha) d\omega$$

Recordad, \mathbf{D} siguen siendo los datos (por ejemplo, un espectro o la curva de velocidad radial)



Modelos jerárquicos I: Inferencia bayesiana

Ventajas:

- Correcta propagación de las incertidumbres
- Posibilidad de hacer selección de modelos
- Selección de la **complejidad** óptima del modelo

¡Cuidado! El conjunto de parámetros e , T , ω , φ , κ , I tiene una complejidad continua.



Posibles aplicaciones en Gaia:

1. Determinación de la distancia a las Nubes de Magallanes
2. Determinación de las distribuciones correspondientes a diferentes componentes de la Galaxia
3. IMFs, SFRs...

