

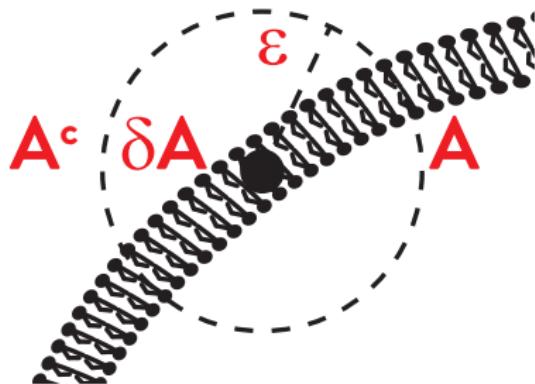
Biología de sistemas - un enfoque continuo

Elisa Domínguez-Hüttiger

Instituto de Investigaciones Biomédicas UNAM

Introducción

Sistemas biológicos: Interacción dinámica con su ambiente



Systems Biology
IIB - UNAM

"The time has come when further progress in our understanding of nature requires that we consider the relationship between the outside and the inside, between organism and environment".

"The characteristic of a living object is that it reacts to external stimuli rather than being passively propelled by them".

"The softness of the boundary between inside and outside is a universal characteristic of living systems".

Lewontin, Triple Helix, 2000.

Acople funcional y dinámico entre organismo - ambiente

$$\frac{dE(t)}{dt} = f(E(t), O(t)) \quad (1a)$$

$$\frac{dO(t)}{dt} = g(E(t), O(t)) \quad (1b)$$

- Fenotipo celular mediada por transducción de señales
- Construcción de nicho / comunidad ecológica
- Usted.

"We need to determine the norms of reaction and the role of [developmental] noise [for each case of interest]".

Lewontin, Triple Helix, 2000.

Sistemas biológicos:

- Dinámicos (diferentes escalas temporales)
- Heterogéneos (diferentes niveles de variabilidad)

entender, formalizar

Retroalimentación - regulación

"In their normal state organisms are buffered against the effects of many internal and external changes by homeostatic regulatory devices"
Lewontin, Triple Helix, 2000.

Objeto de estudio: Redes biológicas dinámicas

"a (developing) organism is a dynamical system in a dynamical structure"

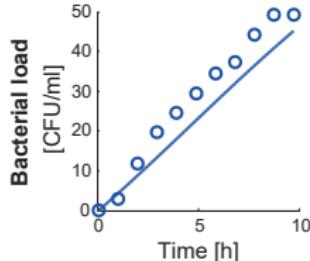
De la biología predictiva a la descriptiva



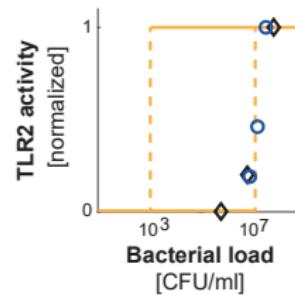
Figure: La Clairvoyance 1936. www.ReneMagritte.org

¿De dónde salen los patrones observados?

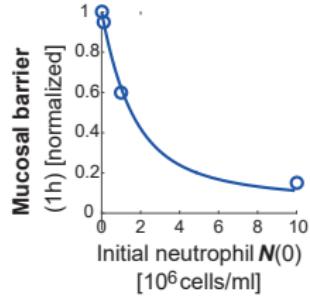
(A)



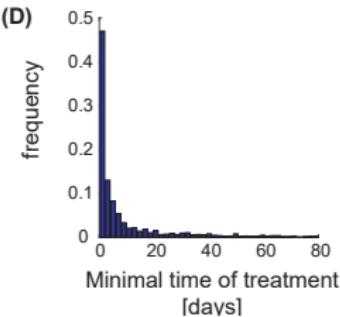
(B)



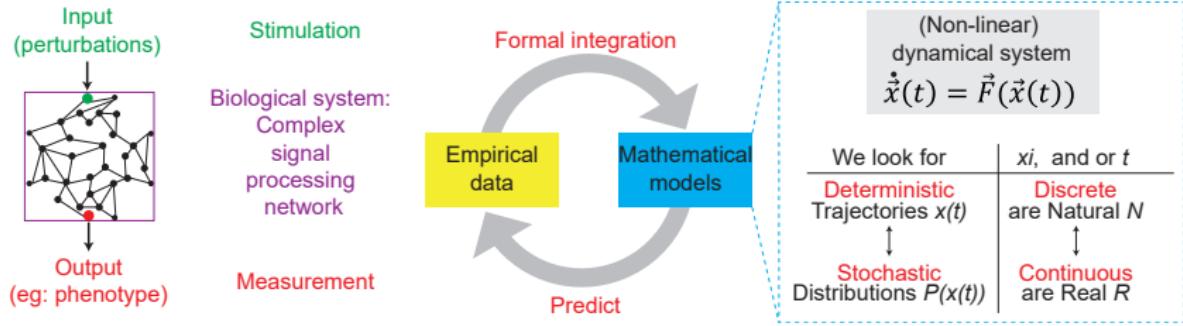
(C)



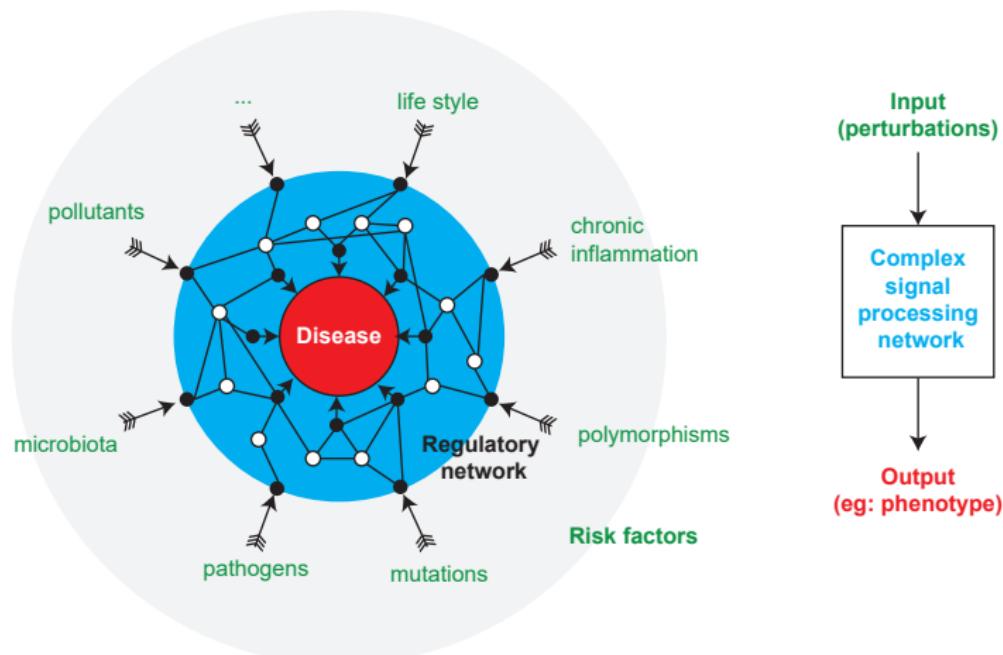
(D)



Biología de sistemas



Para predecir la respuesta del sistema a perturbaciones



Systems biology pipeline

Datos empíricos

Modelos matemáticos

Red de interacciones



Integrar

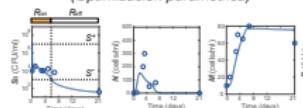
Formalizar

Sistema dinámico

$$\vec{x}(t) = \vec{F}(\vec{x}(t))$$

(Calibrar)

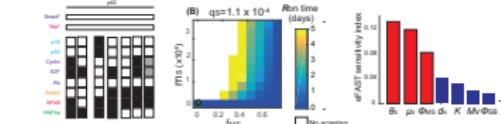
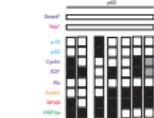
(Optimización paramétrica)



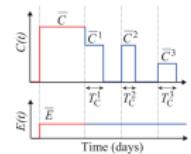
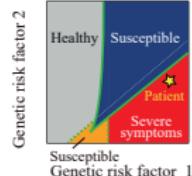
Predicciones

Análisis de perturbaciones

simulación de mutantes análisis de bifurcaciones sensibilidad paramétrica



Detección temprana , estratificación Diseño y optimización de intervenciones



"Progress in biology depends not on revolutionary new conceptualizations, but on creation of new methodologies that make questions answerable in practice in a world of finite resources".

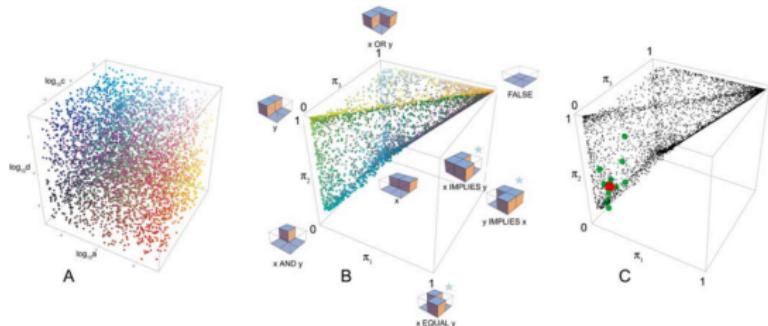
Lewontin, Triple Helix, 2000.

Modelos mecanicistas continuos: Ecuaciones diferenciales

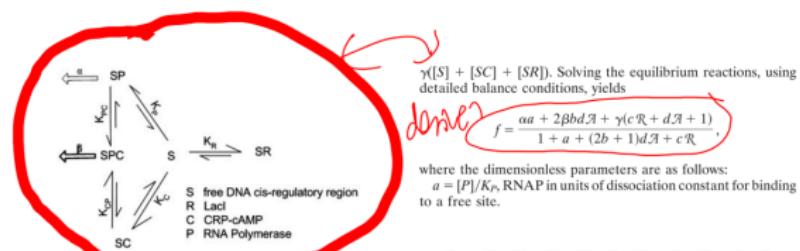
Bienvenidos al mundo real.

(sensu stricto), donde $\bar{x} \in \mathbb{R}^n$ y $t \in \mathbb{R}$. *dejamos atrás el mundo discreto booleano*

¿De dónde salen las compuertas lógicas?

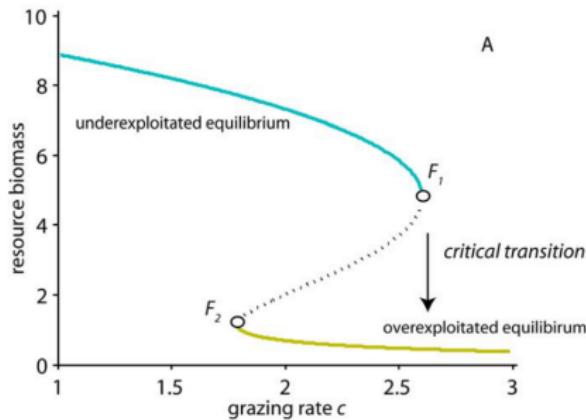


Mayo, A. E., Setty, Y., Shavit, S., Zaslaver, A. Alon, U. PLoS Biol. 4, 555–561 (2006).



Setty, Y., Mayo, A. E., Surette, M. G. Alon, PNAS 100, 7702–7 (2003).

¿Cómo se traducen cambios (ambientales) graduales en decisiones (fenotípicas) abruptas?

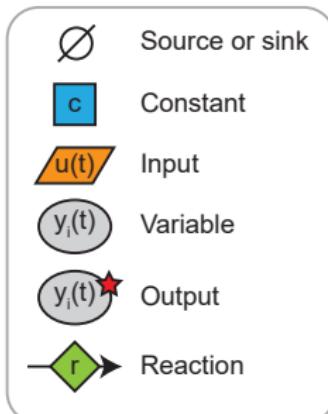


Dakos, V. et al. PLoS One 7, (2012). (¿y cómo se previenen?)

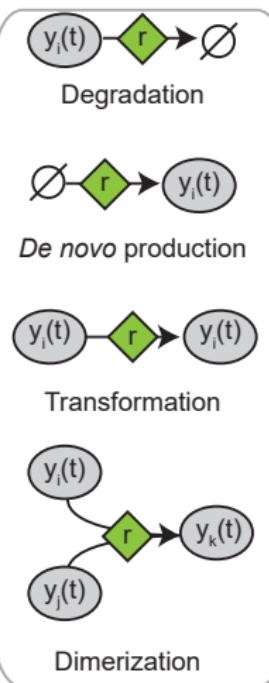
Modulación cuantitativa.

Ley de acción de masas: Notación gráfica

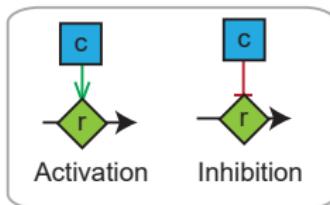
(A) Building blocks



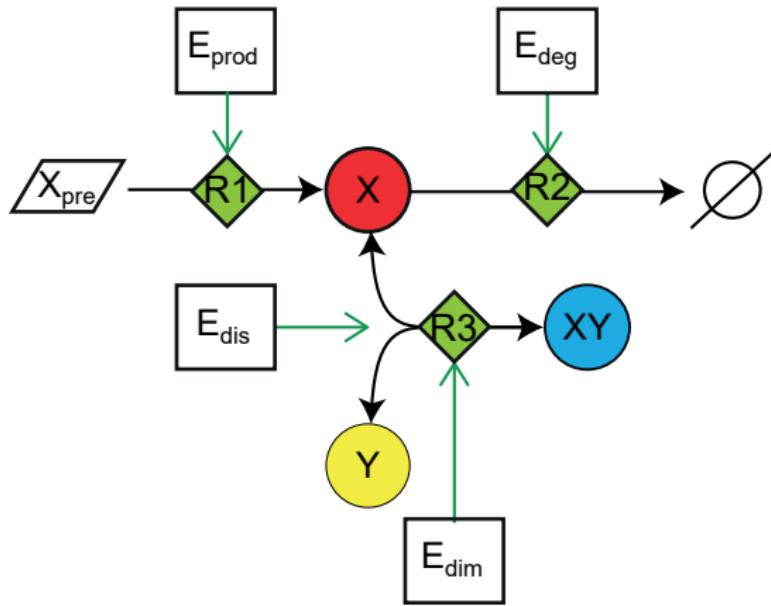
(B) Reactions



(C) Modulations

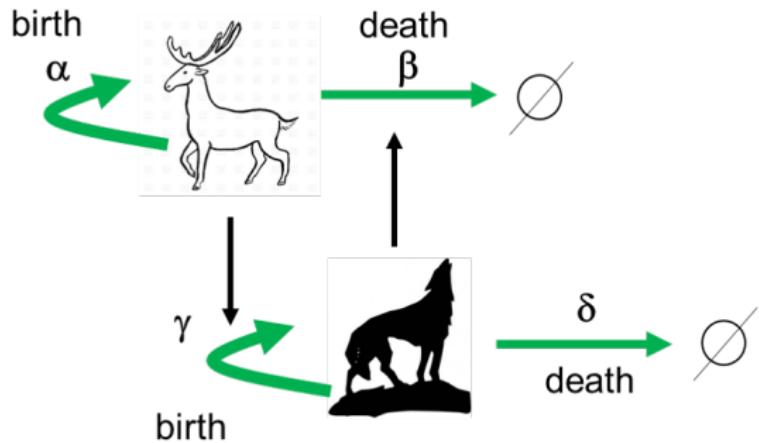


Red de interacción (ejemplo)

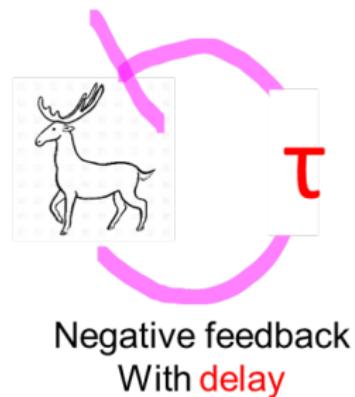


Otro ejemplo, mismo tipo de notación

Regulatory network



Control structure

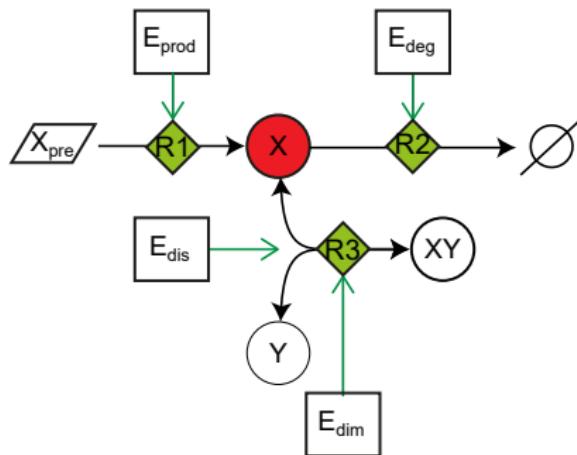


De la red al sistema de ecuaciones

$$F_i(y_1, \dots, y_n, t) = \sum_{j=1}^m R_j. \quad (2)$$

$$R_j = \prod_{p_i=1}^{p_i^{\max}} (Pre_{p_i} \kappa_{p_i}) \prod_{e_i=1}^{e_i^{\max}} (Enz_{m_i} \mu_{e_i}) \quad (3)$$

Red de interacción (ejemplo)



$$\frac{dX(t)}{dt} = \overbrace{X_{pre} k_{prod} E_{prod}}^{\text{R1: de novo production}} - \overbrace{X(t) k_{deg} E_{deg}}^{\text{R2: degradation}}$$

$$-\overbrace{X(t) Y(t) k_{dim} E_{dim}}^{\text{R3+: dimer formation}} + \overbrace{XY(t) k_{dis} E_{dis}}^{\text{R3-: dimer dissociation}}.$$

¿qué nos falta para poder describir a $x(t)$?

Información sobre sus compañeros

Por esto es biología de sistemas: No podemos entender X sin entender también a las otras variables de la red.

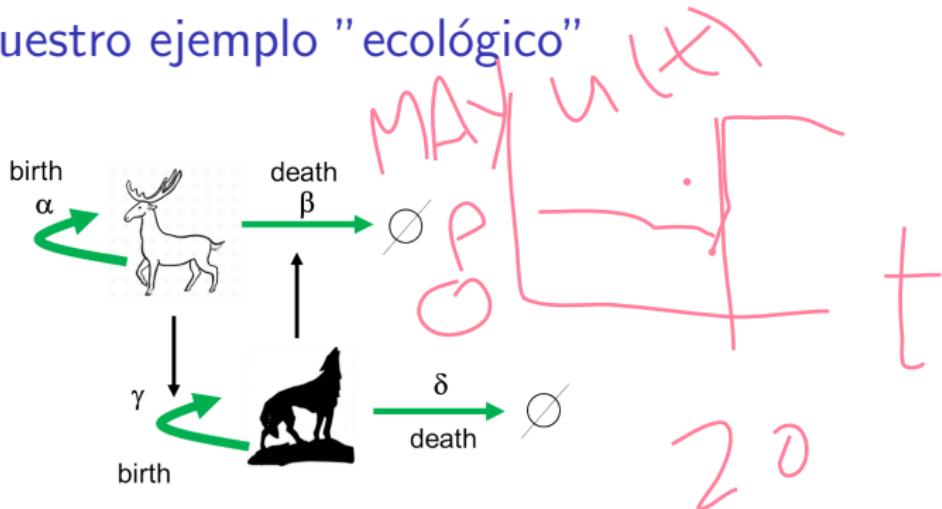
Sistema de ecuaciones

$$\frac{dX(t)}{dt} = \underbrace{X_{\text{pre}} k_{\text{prod}} E_{\text{prod}}}_{\text{R1: de novo production}} - \underbrace{X(t) k_{\text{deg}} E_{\text{deg}}}_{\text{R2: degradation}}$$
$$- \underbrace{X(t) Y(t) k_{\text{dim}} E_{\text{dim}}}_{\text{R3+: dimer formation}} + \underbrace{XY(t) k_{\text{dis}} E_{\text{dis}}}_{\text{R3-: dimer dissociation}}.$$

$$\frac{dY(t)}{dt} = - \underbrace{X(t) Y(t) k_{\text{dim}} E_{\text{dim}}}_{\text{R3+: dimer formation}} + \underbrace{XY(t) k_{\text{dis}} E_{\text{dis}}}_{\text{R3-: dimer dissociation}}, \quad (4)$$

$$\frac{dXY(t)}{dt} = \underbrace{X(t) Y(t) k_{\text{dim}} E_{\text{dim}}}_{\text{R3+: dimer formation}} - \underbrace{XY(t) k_{\text{dis}} E_{\text{dis}}}_{\text{R3-: dimer dissociation}} = - \frac{dY(t)}{dt}. \quad (5)$$

Lo mismo con nuestro ejemplo "ecológico"



prey dynamics

$$\overbrace{\frac{dx(t)}{dt}} = \overbrace{x(t)\alpha} - \overbrace{x(t)\beta y(t)}, \quad (6a)$$

predator dynamics

$$\overbrace{\frac{dy(t)}{dt}} = \overbrace{y(t)x(t)\gamma} - \overbrace{y(t)\delta}, \quad (6b)$$

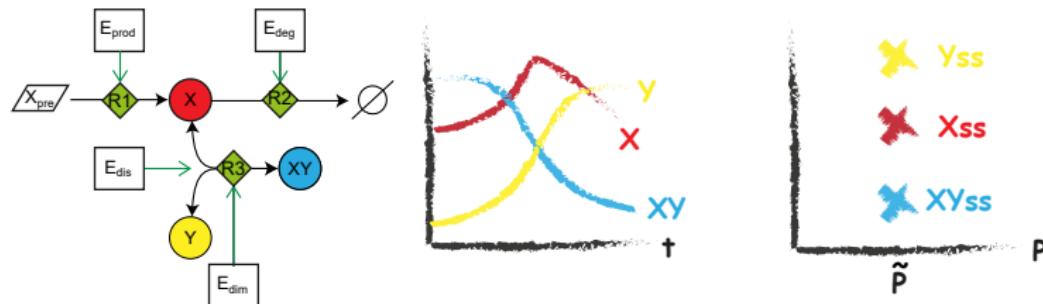
En general: Construimos sistema de ecuaciones diferenciales

Problema de valores iniciales

$$\frac{d\bar{x}(t)}{dt} = \bar{f}(\bar{x}(t), \bar{P}) \quad (7a)$$

$$\bar{x}(0) = \bar{x}_0 \quad (7b)$$

¿Qué le queremos preguntar a nuestro sistema de ecuaciones?



- Queremos encontrar $X(t)$ (y $Y(t), XY(t)$)
- Queremos encontrar X_{ss} (y Y_{ss}, XY_{ss}) ($t \rightarrow \infty$)
- Conocemos: $\frac{dX}{dt}$, $\frac{dY}{dt}$, $\frac{dXY}{dt}$

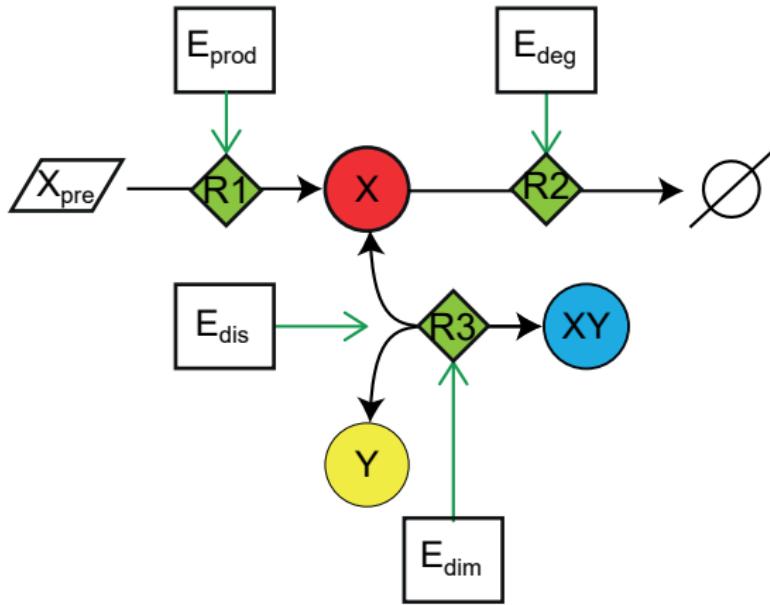
Ecuaciones de conservación

Simplificación del sistema de ecuaciones (reducción del número de dimensiones de las variables dinámicas).

$$\sum_{j=1}^k \frac{dX_j(t)}{dt} = 0 \quad (8a)$$

$$\rightarrow \sum_{j=1}^k X_j(t) = X_k^{\text{total}} = \text{constant.} \quad (8b)$$

Hint: Buscar variables que no se produzcan *de novo* o degraden (sub-sistema cerrado).



Favor de identificar a las variables redundantes.

Ecuaciones de conservación:

$$\frac{dY_T(t)}{dt} = \frac{dXY(t)}{dt} + \frac{dY(t)}{dt} = 0 \rightarrow Y_T = Y(t) + XY(t) = \text{constant. } (9)$$

Reducimos el sistema original (de 3D) a 2D:

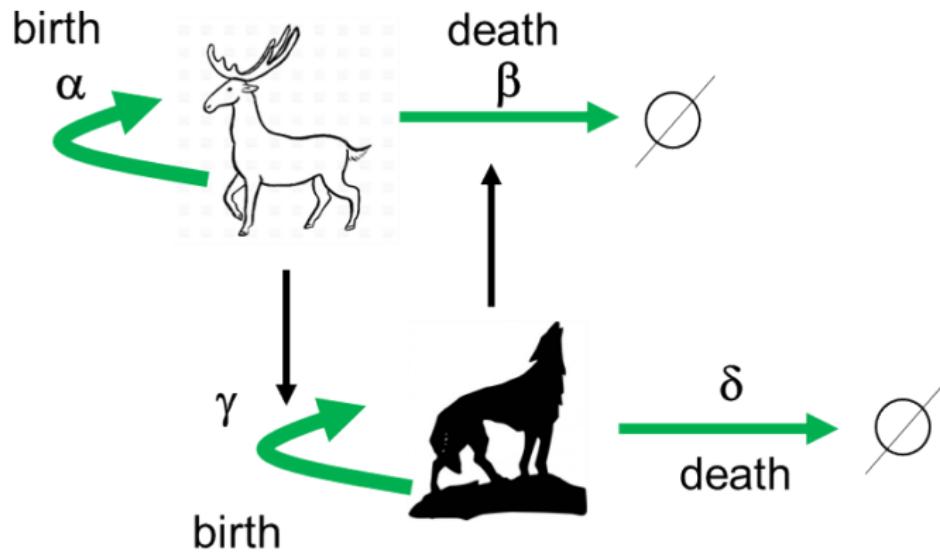
$$\frac{dX(t)}{dt} = X_{\text{pre}} k_{\text{prod}} E_{\text{prod}} - X(t) k_{\text{deg}} E_{\text{deg}}$$

$$- X(t)Y(t)k_{\text{dim}} E_{\text{dim}} + (Y_T - Y(t))k_{\text{dis}} E_{\text{dis}}, \quad (10a)$$

$$\frac{dY(t)}{dt} = -X(t)Y(t)k_{\text{dim}} E_{\text{dim}} + (Y_T - Y(t))k_{\text{dis}} E_{\text{dis}}. \quad (10b)$$

Nota: Claramente no todos los sistemas de ecuaciones pueden reducirse por ecuaciones de conservación.

Contraejemplo



Ok, regresamos a nuestra ecuación (reducida o no).

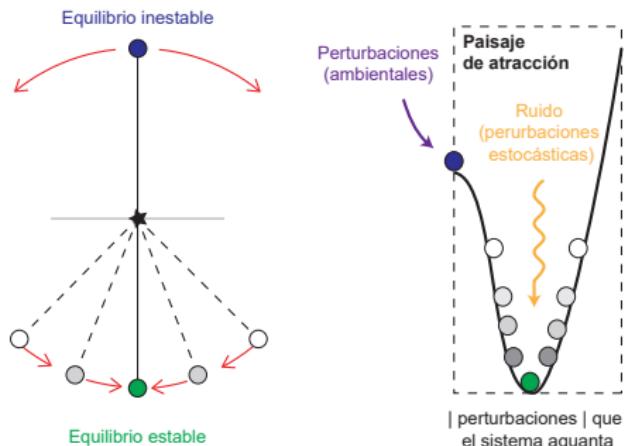
Empezamos por buscar las condiciones de equilibrio

$$\bar{f}(\bar{x}_{ss}, \bar{P}) = 0 \quad (11)$$

En general, no es sencillo (incluso, frecuentemente no es posible) resolver esta ecuación de manejo analítica (polinomios de grado alto). Recurrimos a métodos numéricos: Algoritmo de Newton-Raphson o de Continuación Numérica. **Encontrar las raíces de una función.**

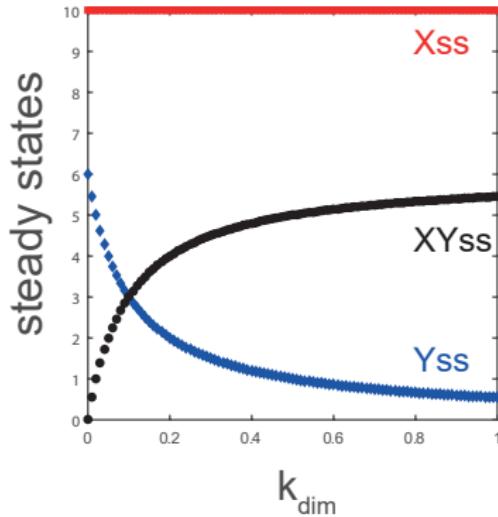
Nota breve sobre estabilidad

Una vez que encontramos los puntos de equilibrio, es importante evaluar su estabilidad. En otras palabras, nos preguntamos: ¿qué sucede si nos alejamos del equilibrio? ¿el sistema regresa? ¿cuántas perturbaciones aguanta?



Linearización (J) para evaluar la estabilidad local.

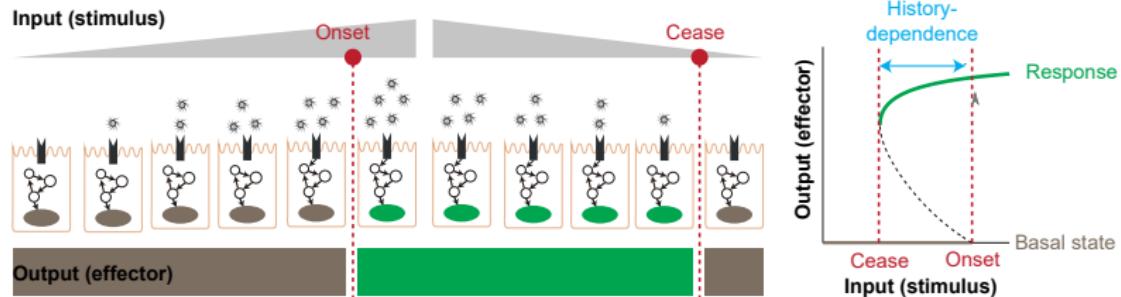
Condiciones de equilibrio



$$[X, Y, XY]_{ss} = \bar{F}(\bar{P}) \quad (12)$$

El punto de equilibrio depende de los parámetros del sistema
(diagrama de bifurcación: mapea relación entre parámetro y equilibrio(s)).

Multi-estabilidad en los sistemas continuos



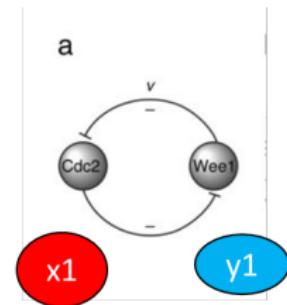
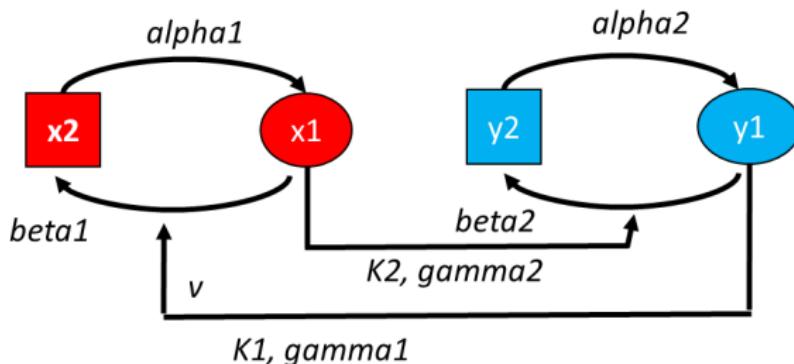
Un sistema de ecuaciones un poco más complejo (más no-linealidades):

David Angeli, James E Ferrell, and Eduardo D Sontag.

Detection of multistability, bifurcations, and hysteresis in a large class of biological positive-feedback systems.

PNAS, 101(7):1822–7, feb 2004.

Para hacer un análisis detallado de este sistema y repasar los temas vistos hasta este punto, faremos el primer ejercicio. En las notas están tanto las preguntas como las respuestas.



$$\dot{x}_1 = \alpha_1(1 - x_1) - \frac{\beta_1 x_1 (\nu y_1)^{\gamma_1}}{K_1 + (\nu y_1)^{\gamma_1}} \quad (13a)$$

$$\dot{y}_1 = \alpha_2(1 - y_1) - \frac{\beta_2 y_1 x_1^{\gamma_2}}{K_2 + x_1^{\gamma_2}} \quad (13b)$$

Ojo:

- Ecuaciones de conservación.
- Retroalimentación positiva y cooperatividad.

Grind.R

<http://theory.bio.uu.nl/rdb/grind.html>

The screenshot shows the homepage of the Grind.R website. At the top, there is a logo for Universiteit Utrecht and a navigation bar with links for 'About us', 'Education', 'Research', and 'Contact'. Below the navigation bar, there is a banner featuring a photograph of a computer monitor displaying a list of microorganisms: *Azotobacter*, *Oryza sativa*, *Oryctostelum discoidatum*, *Schizosaccharomyces pombe*, *Saccharomyces cerevisiae*, *Eremothecium gossypii*, *Caenorhabditis briggsae*, and *Caenorhabditis elegans*. To the left of the banner is a portrait photo of Rob J. de Boer. On the right side of the page, there is a sidebar titled 'Research groups' listing several groups: De Boer group, Snel group, Hogeweg group, Konijn group, Hemmam group, Tan Tuscher group, Dutil group, and Bonnep group. At the bottom of the page, there is a 'CONTACT' button and a footer with the Universiteit Utrecht logo.

Phase plane analysis is a powerful approach for analysing mathematical models comprised of a few ordinary differential equations (ODEs). grind.R is an R script allowing one to easily study such models by numerical integration, phase plane analysis, finding and following steady states, and fitting to data. grind.R is a successor around Rlibm developed by Karline Bester and colleagues. Grind is easy to use because it defines just a few basic functions:

- `integrate()` does model numerically and provides a time plot or trajectory in the phase plane,
- `phase()` draws nullclines and can provide a vector field or phase portraits,
- `nearest()` finds steady states (using the Newton-Raphson method) and can provide the Jacobian with its eigenvalues and eigenvectors,
- `follow()` follows steady states along a parameter,
- `fit()` fits an ODE model to data by estimating its parameters, and depends the result in a template.

The `run()` function calls `ode()` from the deSolve package, the `R2C()` function calls `model()` from R2C, and `nearest()` and `integrate()` call `lsoda()` from the lsoda package (these 3 packages have to be installed). The `grind()` functions have several options with well-known defaults (like for the state (`x`) and parameter(`p`) of the system), such that they are typically well-behaved when no options are provided. Using `lsody` in R one can easily extend it for analysing particular models using `algebra` for changing parameters (see a [usage example](#)).

We use grind.R in our courses for biology students at Utrecht University because it allows them to easily analyse mathematical models, see their dynamical behavior on the screen, and export high quality graphics for reports. Researchers may also like grind.R because it allows them to easily define and study simple ODE models, to analyse steady states, initial and events, and to do linear parameter estimation, while fitting several data sets simultaneously having unique and shared parameters (using the state-of-the-art environment `npqr`).

A tutorial, a `grind.R` script, and a number of examples can be downloaded from the [download](#).

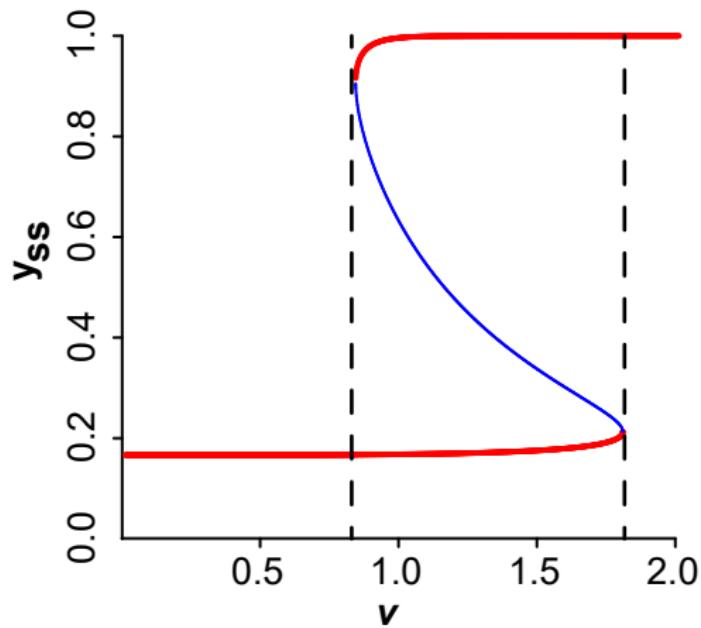
Grind is basically an iteration of an earlier program called GRIND. The installation instructions of GRIND are still available on this [web page](#) for download. See this [page](#) for a translation of GRIND commands into R.

Obtener puntos de equilibrio

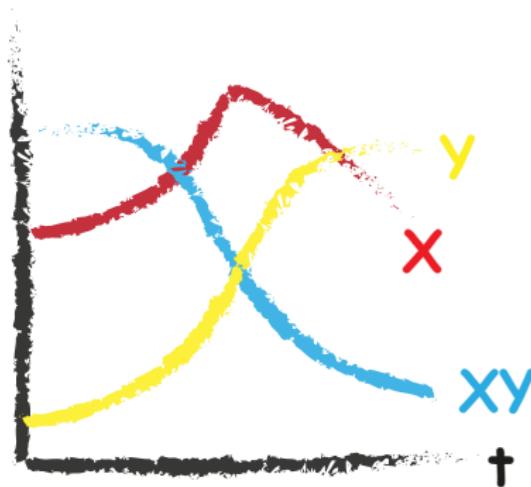
Algoritmo de continuación numérica para generar un diagrama de bifurcación (con GrindR)

```
BifDiagAngeli.R
```

Bistabilidad e histéresis



$\bar{X}(t)$



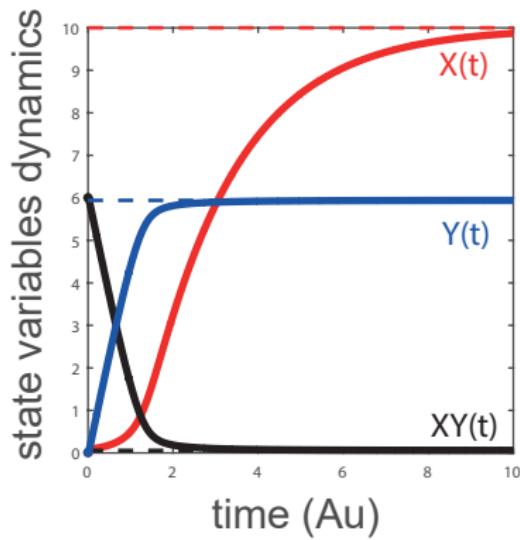
Ahora queremos reconstruir $\bar{X}(t)$. Recuerden, lo que conocemos es $\frac{d\bar{X}(t)}{dt} = \bar{F}(\bar{X}(t), \bar{P})$. Con muy pocas excepciones, utilizamos (nuevamente) **métodos numéricos** (Ej. Runge-Kutta, Euler) para deducir $\bar{X}(t)$ a partir de $\frac{d\bar{X}(t)}{dt} = \bar{F}(\bar{X}(t), \bar{P})$.

Integración numérica de ecuaciones diferenciales

- ① Declara la función $\frac{d\bar{X}(t)}{dt} = \bar{F}(\bar{X}(t), \bar{P})$
- ② Declara los valores de parámetro \bar{P}
- ③ Define las condiciones iniciales $\bar{x}(t_0) = \bar{x}_0$
- ④ Define el intervalo de integración $t = [0 : \Delta t : t_{end}]$.
- ⑤ Invoca al integrador - para obtener $\bar{x}(t)$.

Veamos un ejemplo. `Red_ejemplo_Integrar.r`

```
library(deSolve)
# (1) Declara la funcion
RedEjemplo <- function(t, y, parms){
  X_t=y[1]; Y_t=y[2];XY_t=(parms[6]-Y_t);
  dX=parms[1]*parms[2]-X_t*parms[3]-X_t*Y_t*parms[4]+XY_t*parms[5];
  dY=-X_t*Y_t*parms[4]+XY_t*parms[5];
  list(c(dX,dY)) }
# (2) Declara los valores de parametro
Xpre=10;kprodEprod=.5;kdegEdeg=.5;kdimEdim=10;kdisEdis=1;Ytot=6;
parms=c(Xpre,kprodEprod,kdegEdeg,kdimEdim,kdisEdis,Ytot);
# (3) Define las condiciones iniciales
y0=c(0, Ytot);
# (4) Define el intervalo de integracion
tspan =seq(from = 0, to = 5, by = 0.01)
# (5) Invoca al integrador -
out <- ode(y = y0, times = tspan, func = RedEjemplo, parms =
  parms)
# Grafiquemos los resultados
par(pty="s")
plot(out[,1], out[,2],type = "l", col="red", xlab = "Time", ylab
  ="[X(t), Y(t), XY(t)]")
```



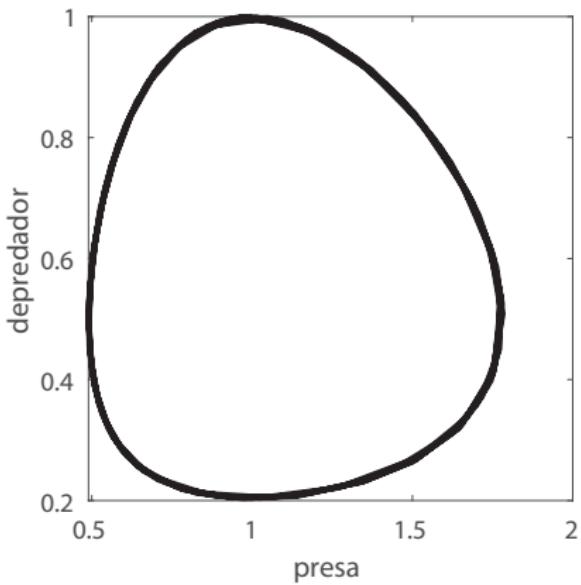
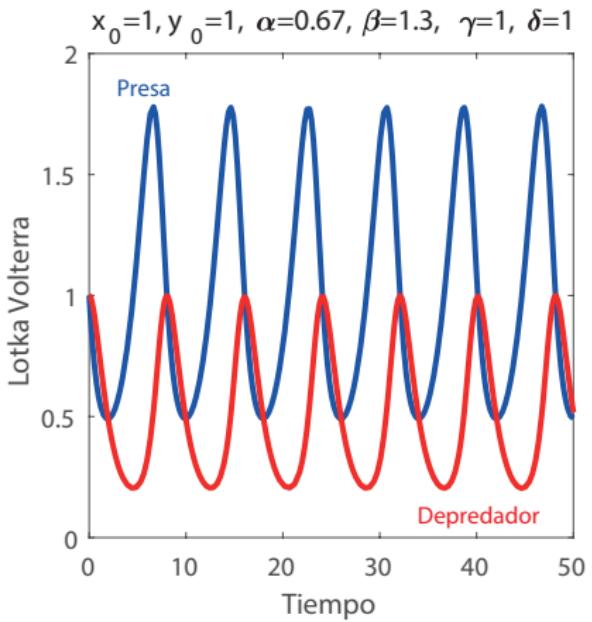
Lo mismo para nuestro ejemplo de Lotka Volterra

(esta vez se los muestro en Matlab; es equivalente)

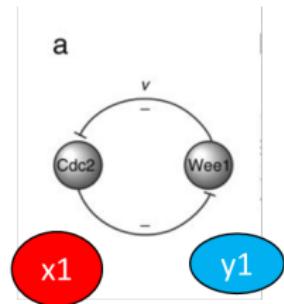
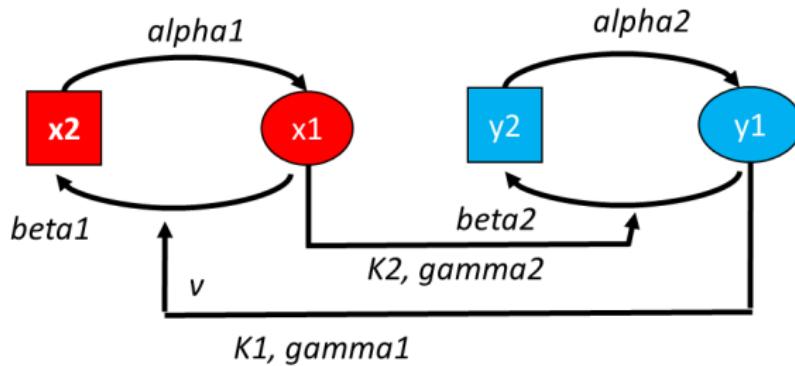
LotkaVolterra_LIBRO.m

```
1 function LotkaVolterra_LIBRO
2 % Como siempre, buena costumbre limpiar nuestro espacio de
3 % trabajo antes
4 % de comenzar
5 close all; clear all; clc
6
7 % condicion inicial:
8 x0=1; y0=1; IC=[x0 y0];
9
10 %Parametros
11 alpha = 2/3; beta= 4/3; gamma=1; delta=1;
12
13 %tiempo de integracion
14 tspan = [0 50];
15
16 %integraremos numericamente:
17 [t,y] = ode45(@(t,y)Lotka_Volterra(t,y, alpha, beta, gamma,
```

Lotka Volterra



... Y para nuestro ejemplo bi-estable

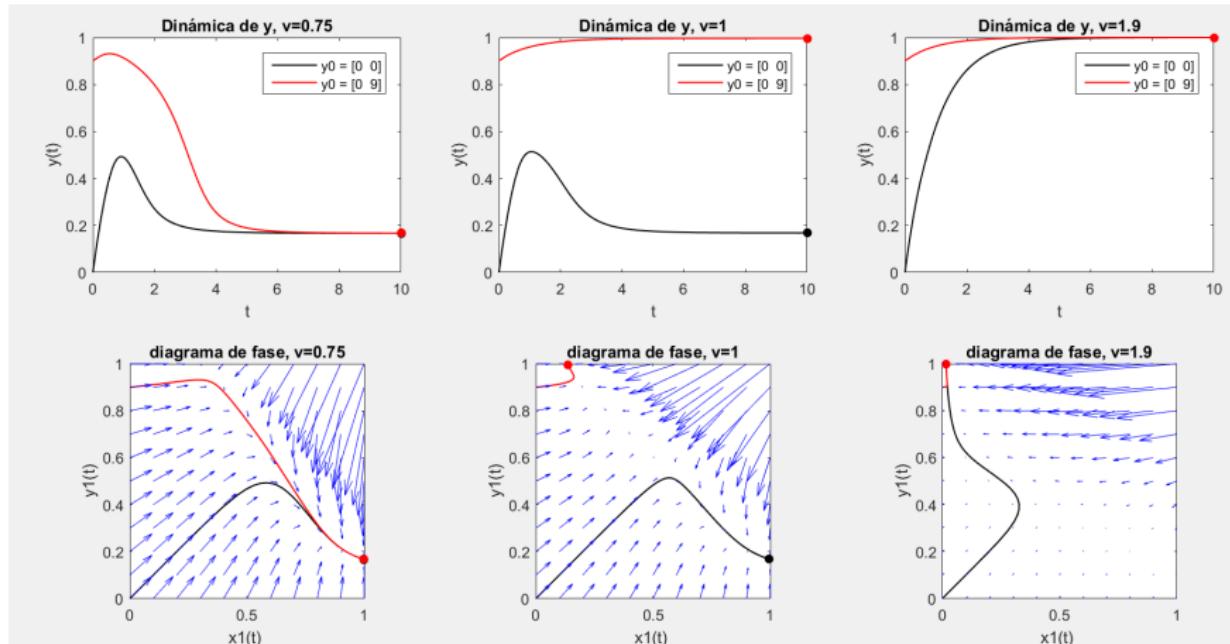


$$\dot{x}_1 = \alpha_1(1 - x_1) - \frac{\beta_1 x_1 (\nu y_1)^{\gamma_1}}{K_1 + (\nu y_1)^{\gamma_1}} \quad (14a)$$

$$\dot{y}_1 = \alpha_2(1 - y_1) - \frac{\beta_2 y_1 x_1^{\gamma_2}}{K_2 + x_1^{\gamma_2}} \quad (14b)$$

(veamos un poco cuáles son las consecuencias dinámicas de la
biestabilidad)

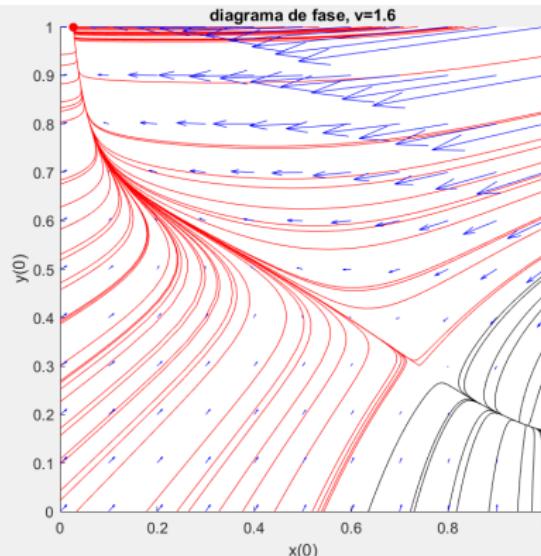
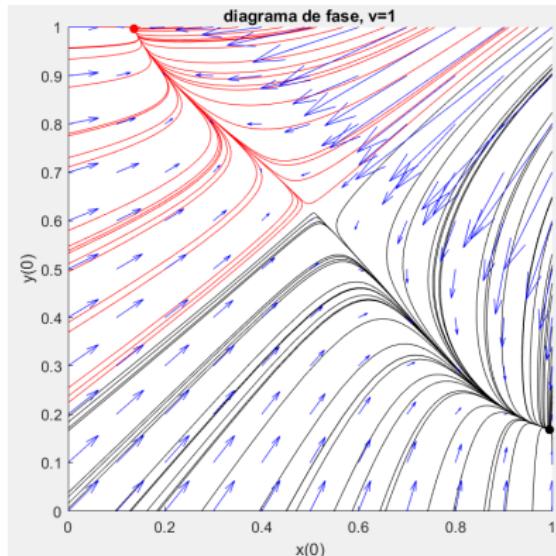
Bi-estabilidad: dependencia de condiciones iniciales



(Figuras hechas en matlab: PracticaAngeli.m; lo mismo obtendrán con Practica_2_ODEs_Angeli.r).

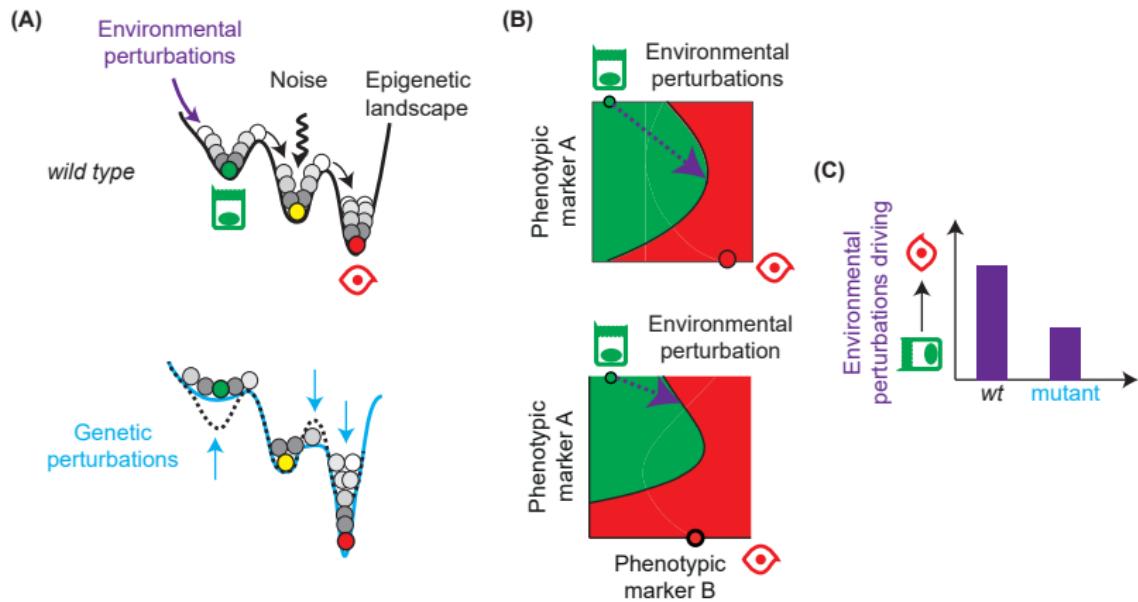
Espacio fase

Separatriz depende del valor del parámetro de bifurcación.

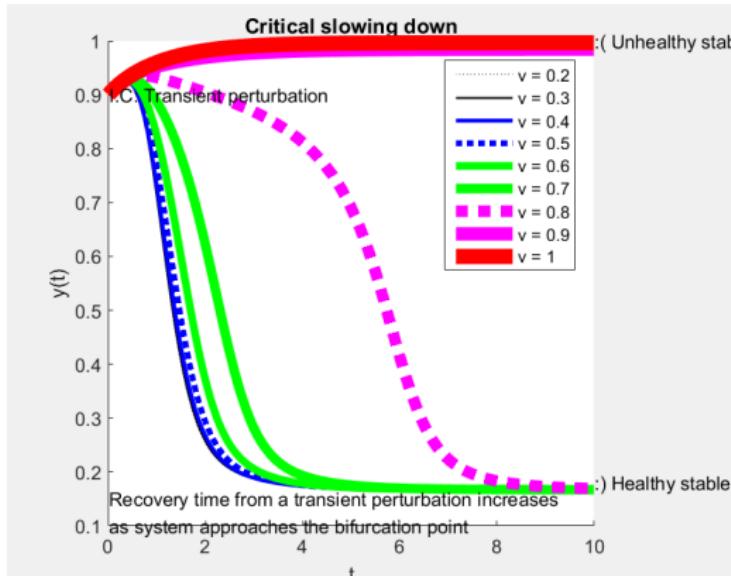


Nota: *Encontrar separatrices no es trivial.*

Vasijas de atracción



Señales de alerta temprana: Alentamiento crítico



El sistema presenta cambios en su comportamiento dinámico (y estadístico) cuando se aproxima una bifurcación. (**Teoría de catástrofes**)

Optimización paramétrica

Supongamos que tenemos la fortuna de contar con datos datos (¡Felizmente, es una suposición razonable en este curso!) Queremos encontrar el conjunto de parámetros \bar{P}) tal que nuestro modelo coincida "lo mejor posible" con los datos experimentales \bar{x}_{exp} . Dicho de otro modo, queremos **minimizar**:

$$\text{cost}(\bar{P}) = \sum_{i=1}^k (\bar{x}_{\text{exp}}(t_i) - \bar{x}(t_i, \bar{P}))^2 \quad (15)$$

Es decir, encontrar:

$$\min(\text{cost}(\bar{P})) = \text{cost}(\bar{P}_{\text{opt}}) \quad (16)$$

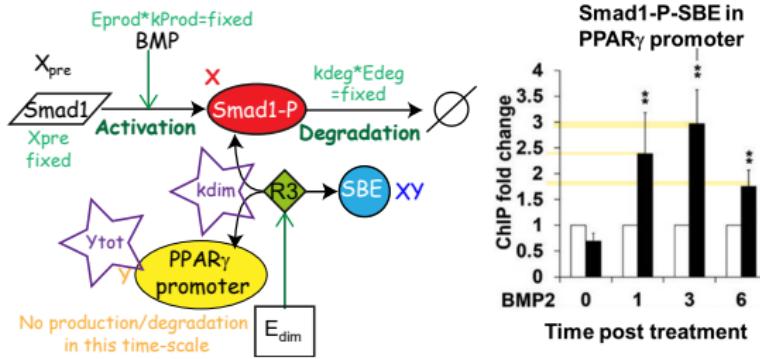
Una vez más, utilizamos para ello un algoritmo de optimización numérica, ej. **Neadler-Mead** (ojo, es local) (o la opción más elegante: usar un algoritmo global (ej. **Simmulated Annealing**).

Grind.R

<http://theory.bio.uu.nl/rdb/grind.html>

The screenshot shows the homepage of the Grind.R website. At the top, there is a logo for Universiteit Utrecht and a navigation bar with links for 'About us', 'Education', 'Research', and 'Contact'. Below the navigation bar, there is a banner featuring a grayscale photograph of laboratory glassware (flasks) and a list of yeast species: *Aleurostachys*, *Oryza sativa*, *Ochyostelium discideum*, *Saccharomyces pombe*, *Saccharomyces cerevisiae*, *Eremothecium gossypii*, *Caenorhabditis briggsae*, and *Caenorhabditis elegans*. The main content area features a portrait of Rob J. de Boer, a man with glasses and a white shirt. To his right, there is a sidebar titled 'Research groups' listing several groups: De Boer group, Snijl group, Hogeweg group, Konijn group, Hemmink group, Tan Tuscher group, Dutilh group, and Bonnepart group. Below the sidebar is a 'CONTACT' button. The central column contains text about the software, including its purpose (phase plane analysis), how it works (numerically integrates ODEs), and its features (finding steady states, fitting to data, etc.). It also includes a 'CONTACT' button and a 'CONTACT' link. At the bottom of the page is a footer with the Universiteit Utrecht logo and a series of small navigation icons.

Regresemos a nuestra red ejemplo



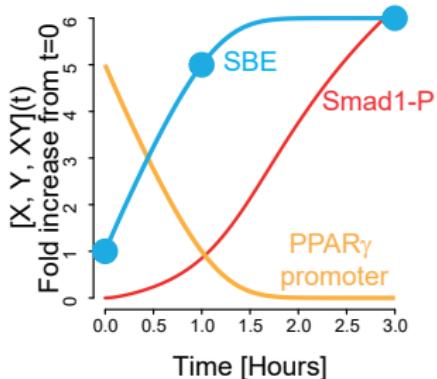
- **Data from:** Sunmee Shin, Je Kyung Seong, and Yun Soo Bae. Ahnak stimulates BMP2-mediated adipocyte differentiation through Smad1 activation. *Obesity*, 24(2):398–407, 2016.
- **Model:** our toy model (equations 27)

Optimizacion_Parametrica.r

Optimización paramétrica en R (con *GrindR*)

```
1 model <- function(t, state, parms){  
2   with(as.list(c(state,parms)), {  
3     dX_t=Xpre*kprodEprod-X_t*kdegEdeg-X_t*Y_t*  
4       kdimEdim+(Ytot-Y_t)*kdisEdis;  
5     dY_t=-X_t*Y_t*kdimEdim+(Ytot-Y_t)*kdisEdis;  
6     dXY_t=-dY_t;  
7     return(list(c(dX_t, dY_t, dXY_t)))  
8   }) }  
9 p=c(Xpre=10, kprodEprod=.5, kdegEdeg=.5, kdimEdim=10,  
10   kdisEdis=1, Ytot=6);  
11 s <- c(X_t=0, Y_t=5, XY_t=1) # s is the state  
12 data <- data.frame("time"= c(0, 1, 3) , "XY_t"=c(.5, 2.5, 3 )/.5 )  
13 w <- c("kdimEdim", "Ytot") # free parameters # to be optimized  
14 f=fit(legend=FALSE, free=w, tstep=0.01) #method="Nelder-Mead"
```

Resultados para nuestra red ejemplo



- Error (diferencia [mínima] entre modelo y datos):
 $SSR = 2.61319 \times 10^{-14}$
- Parámetros óptimos: $k_{dim} \times E_{dim} = 2.056827$, $Y_{tot} = 1.65 \times 10^{-6}$

Optimización paramétrica: ¿para qué?

- Deducir lo que no podemos medir.
- Evaluar qué tan plausible es un modelo (+ penalización por número de parámetros + evaluar su capacidad de predicción de datos nuevos). Ver por ejemplo:

Cedersund, G. and Roll, J. Systems biology: Model based evaluation and comparison of potential explanations for given biological data. FEBS J. 276, 903–922 (2009).

Análisis de robustez

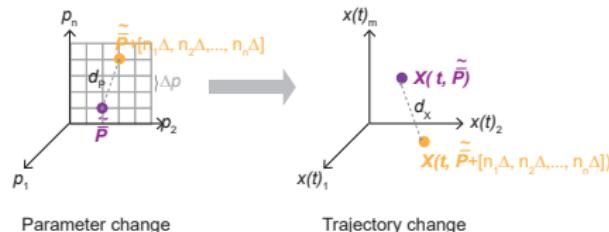


Divergencia de un estado nominal del sistemas a partir de simulación de perturbaciones (parámetros, estructural, ruido interno, forcing...)

Más adelante (modelos estocásticos) veremos cómo simular perturbaciones aleatorias.

Análisis de sensibilidad paramétrica

¿quién es el culpable? (¿qué tan robusto es el modelo ante alteraciones paramétricas?)



Queremos entender cómo se relacionan las variaciones en el espacio de parámetros *barP* ("genotipos") con las variaciones en el espacio de variables dinámicas $\bar{x}(t)$

- Morris's Elementary Effects:

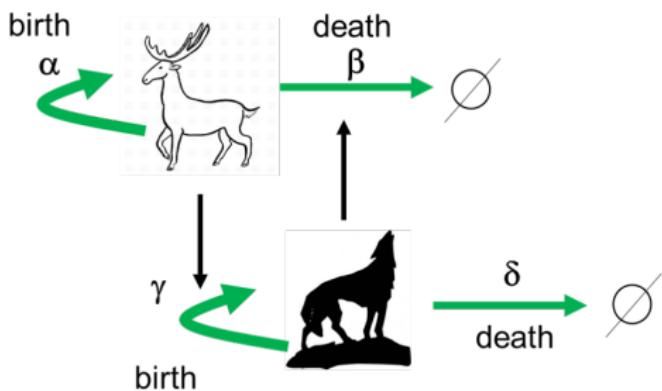
$$\frac{\partial f}{\partial x_i} \quad (17)$$

- Sobol's sensitivity index (Variance decomposition):

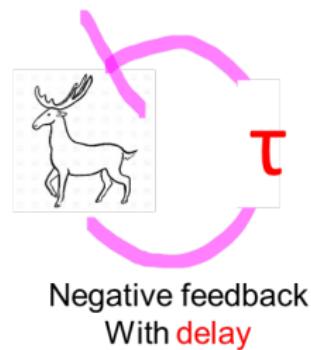
$$D_I = \text{Var}(f_I(x_I)) \text{Var}(f(x)) \quad (18)$$

Análisis de sensibilidad paramétrica: ejemplo

Regulatory network



Control structure

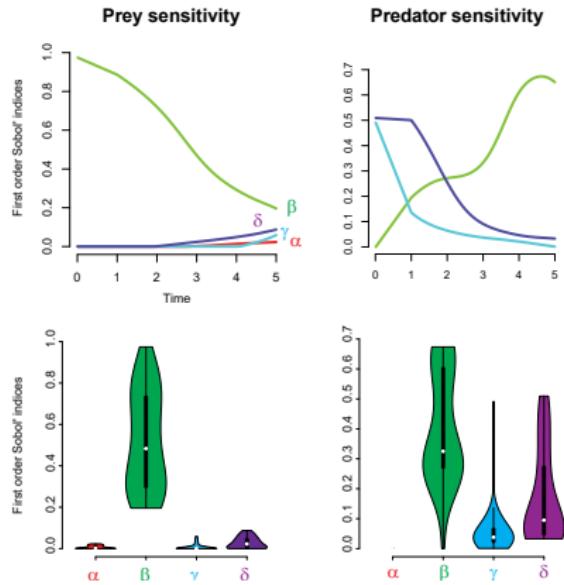
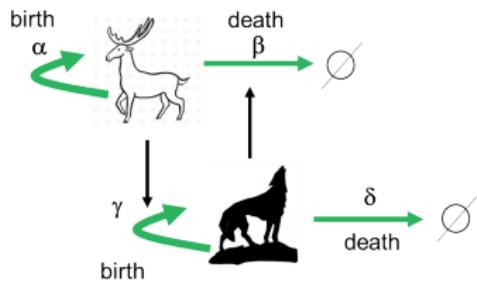


Análisis de sensibilidad paramétrica en R

```
1 library(deSolve); library(sensitivity)
2 library(checkmate); library(ODEnetwork)
3 library(ODEsensitivity)
4 ##### Lotka-Volterra equations #####
5 LVmod <- function(Time, State, Pars) {with(as.list(c(State,
6     Pars)), {
7         dPrey      <- alpha*Prey-beta*Prey*Predator
8         dPredator <- gamma*Prey*Predator- delta*Predator
9         return(list(c(dPrey, dPredator))))}
10 # The parameters, their lower and upper boundaries:
11 LVpars <- c("alpha", "beta", "gamma", "delta")
12 LVbinf <- c(0.05, 0.05, 0.05, 0.05); LVbsup <- c(1.00, 3.00,
13     0.95, 0.95)
14 LVinit <- c(Prey = 1, Predator = 2) #initial conditions
15 LVtimes <- c(0.01, seq(1, 5, by = 0.1)) # The timepoints of
16     interest:
17 set.seed(59281)
18 LVres_sobol= ODEsobol(mod = LVmod, pars = LVpars,state_init =
19     LVinit, times = LVtimes,
```

Análisis de sensibilidad paramétrica: ejemplo

Regulatory network



Ecuaciones diferenciales ordinarias: Recapitulación

- Construcción de red: Nodos y procesos; "moléculas" y "reacciones". Efectores, precursores.
- Formalización a un modelo matemático: Ley de acción de masas.
 $\dot{\bar{x}}(t) = \bar{F}(\bar{x}(t), \bar{P})$
- Evaluación de puntos de equilibrio: Resolver $\dot{\bar{x}}(t) = 0$ (algoritmo de Newton-Raphson, de continuación numérica). Análisis de bifurcaciones.
- Integrar $\dot{\bar{x}}(t) = \bar{F}(\bar{x}(t), \bar{P})$ (Runge-Kutta, Euler)
- Optimización paramétrica.
- Análisis de sensibilidad paramétrica.

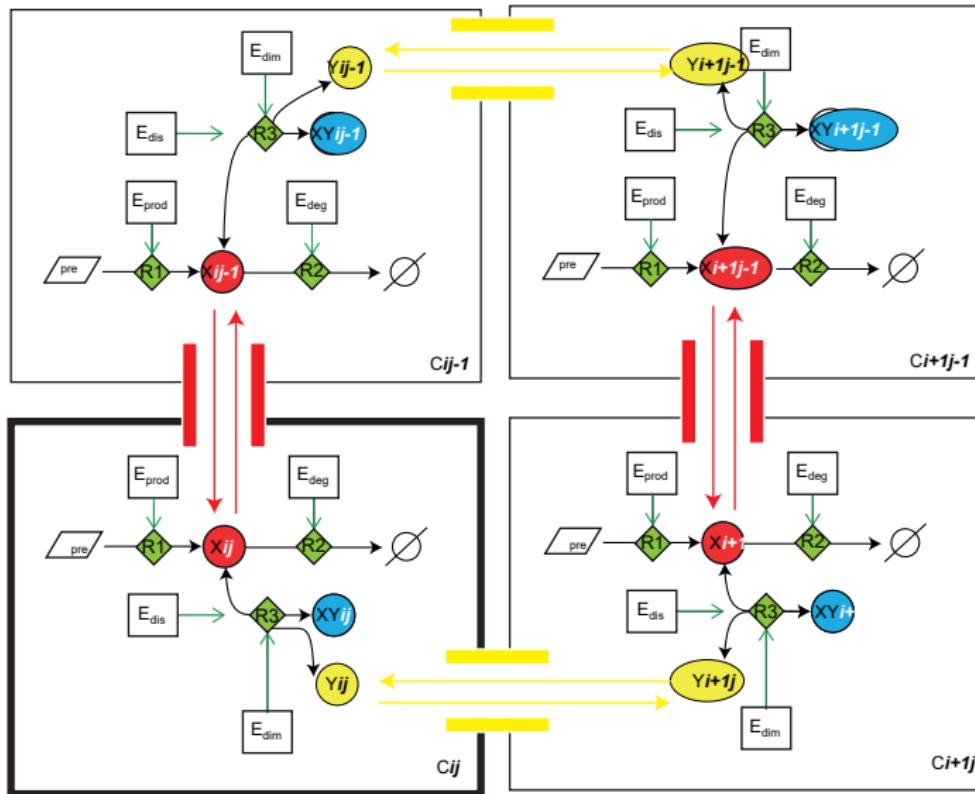
... y si eso no fuera suficiente:

Ecuaciones diferenciales ordinarias: Un buen punto de partida para abordar problemas más complejos. Dependiendo de nuestros requerimientos, es decir, **de la pregunta que queramos responder**, podemos "fácilmente" extender nuestro modelo para incluir, explícitamente:

- Heterogenidad espacial: Modelos en compartimentos.
- Forcing externo: *events function*
- Más escalas temporales: *Quasi-steady state assumption*
- Retardos: *Delay differential equations*
- Ruido
 - ▶ Intrínseco: *Chemical Master Equation* (algoritmo de Gillespie)
 - ▶ Extrínseco (muestrear parámetros y condiciones iniciales de distribuciones)
 - ▶ Estructural (ruido aditivo)

Stochastic differential equations

Heterogeneidad espacial: Modelo en compartimentos



Heterogeneidad espacial: Modelo en compartimentos

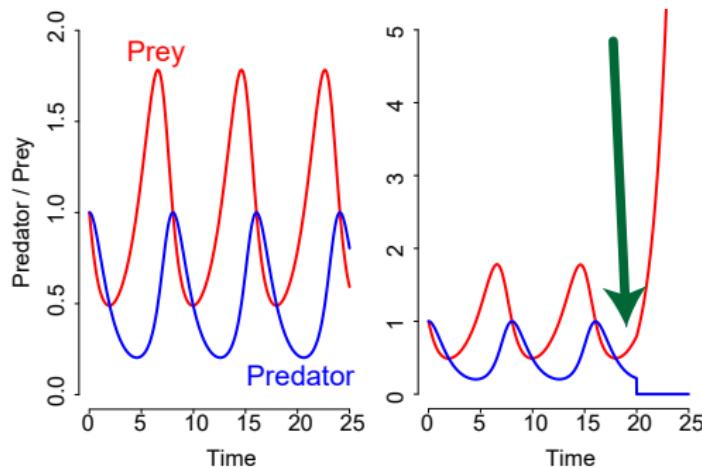
- Ley de acción de masas: "precursores de compartimentos".
- Cuidado con cómo crece el sistema con el número de compartimentos ($\# \text{ variables} \times \# \text{ de compartimentos}$)
- Si $\# \text{ compartimentos}$ es grande ($\rightarrow \infty$): PDEs. (añadir un término difusivo: ej. ecuaciones de reacción-difusión).
- Otras opciones de modelos espaciales: modelo basado en agentes.

Forcing externo: Events function

Por ejemplo: (con Grind.R):

```
run(after="if(t==20)state[\"N\"]<-0")
```

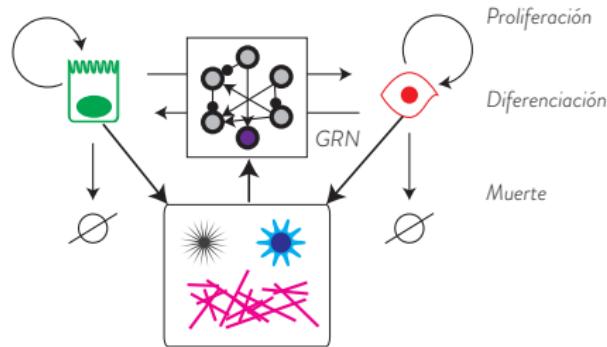
Extinción de los depredadores al tiempo 20.



Grind_events.r

Modelos multi-escala

- Regulatory interplay between fast phenotype changes and slow microenvironmental dynamics (muy ecológico)
- Quasi-steady state assumption (QSSA)
- Events location function

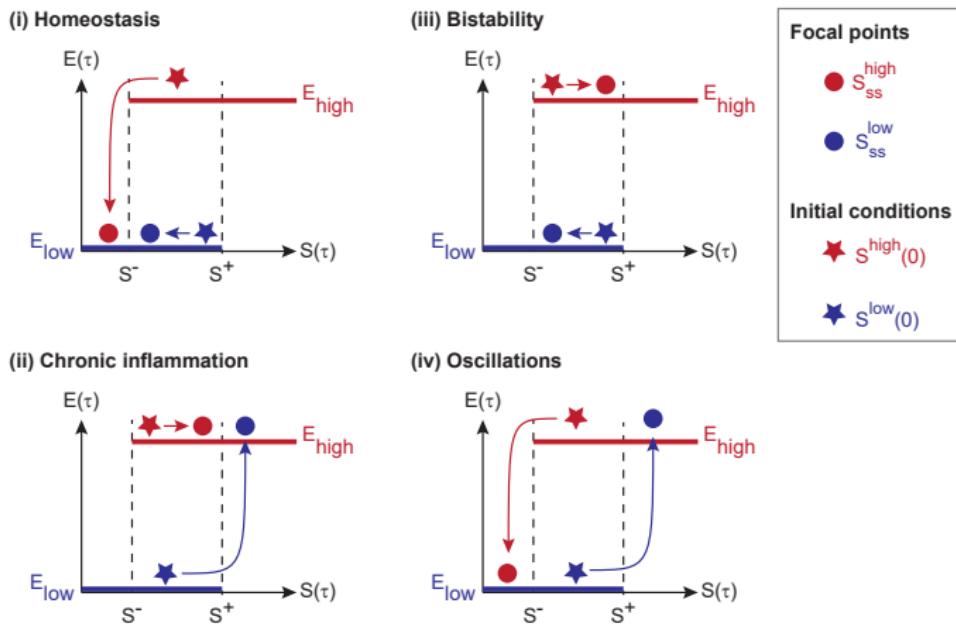


Ejemplos ecológicos:

- Sucesión ecológica (ej en REPSA);

Paseando en el diagrama de bifurcación

Cuando el parámetro de bifurcación (de un sistema bi-estable) es función (dinámica) del punto de equilibrio del sistema. → Análisis de puntos focales: comportamientos emergentes (nuevas bifurcaciones)



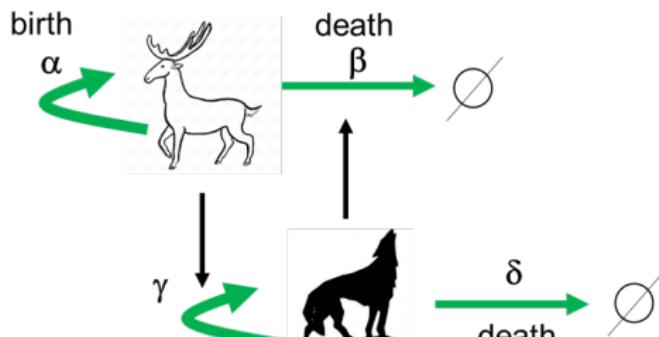
Retardos

Delay differential equations Algunas cosas toman tiempo

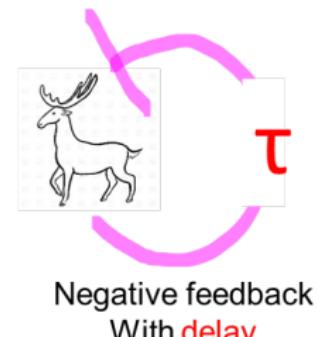
$$\frac{d\bar{x}}{dt} = \bar{F}(\bar{x}(t), x(t - \tau)) \quad (19)$$

$$\frac{dP(t)}{dt} = \alpha P(t) - \beta P(t)P(t - \tau) \quad (20)$$

Regulatory network



Control structure

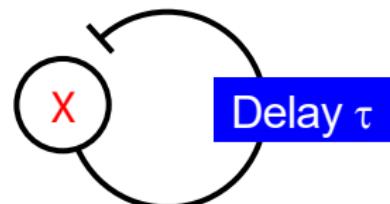
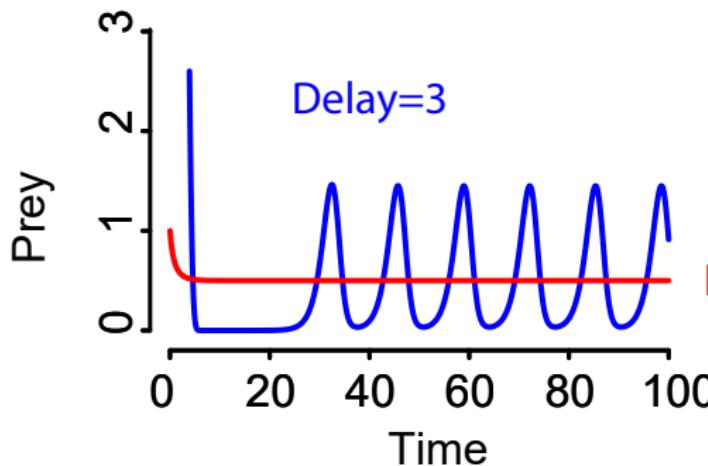


Nuevamente: Grind.R |

```
1 model <- function(t, state, parms) {
2   with(as.list(c(state,parms)), {
3     tlag <- t - Delta
4     if (tlag < 0) lags <- 0 # no initial predation
5     else lags <- lagvalue(tlag) # returns lags of P
6     dP <- alpha*P - beta*P*lags[1]
7     return(list(dP)) })
8 p <- c(alpha=2/3,beta=4/3,Delta=3)
9 run(delay=TRUE, ylab="Prey", ymax=5, tmax=100, tstep=0.1,
10    legend=FALSE)
11 p <- c(alpha=2/3,beta=4/3,Delta=0)
12 run(delay=TRUE, ylab="Prey", ymax=5, tmax=100, tstep=0.1,
13    legend=FALSE)
```

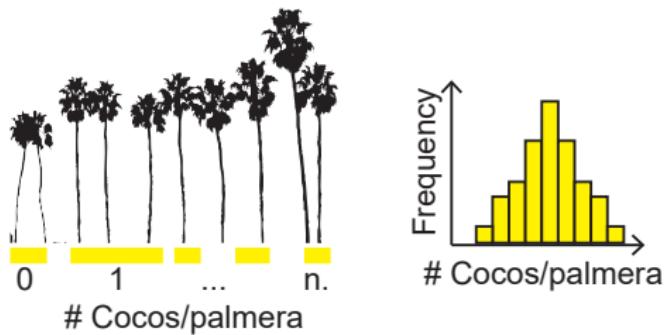
DDE_lotka_volterra.R

Emergencia de oscilaciones en un sistema uni-dimensional

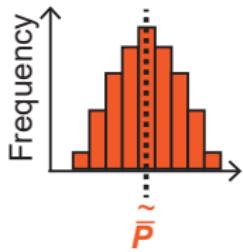


Ruido.

¿de dónde salen las distribuciones poblacionales?



Variación en Parámetros:



k_p

producción

k_m

C
muerte



Ruido intrínseco

Ruido estructural

Fuentes de ruido (y cómo modelarlas)

- Extrínseco (muestrear parámetros y condiciones iniciales de distribuciones)
- Estructural (ruido aditivo)
- Intrínseco: *Chemical Master Equation* (algoritmo de Gillespie)

Ecuaciones diferenciales estocásticas

¿de dónde salen las distribuciones?

The rest is noise

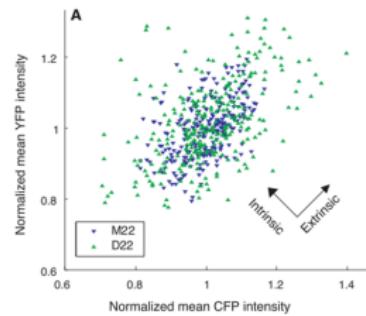
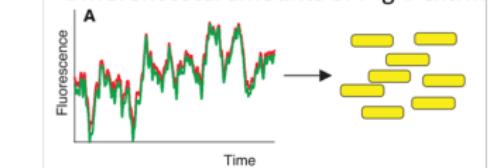


Now its about populations (Remark on Darwin; Dialectical biologist, Lewis and Lewontin)

Intrinsic vs extrinsic noise

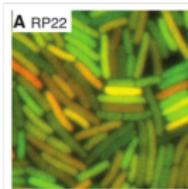
No intrinsic noise → correlation

Different total amounts of r+g → extrinsic



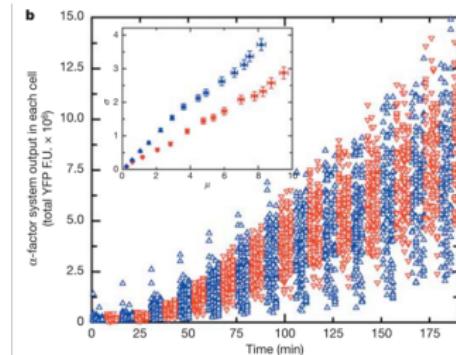
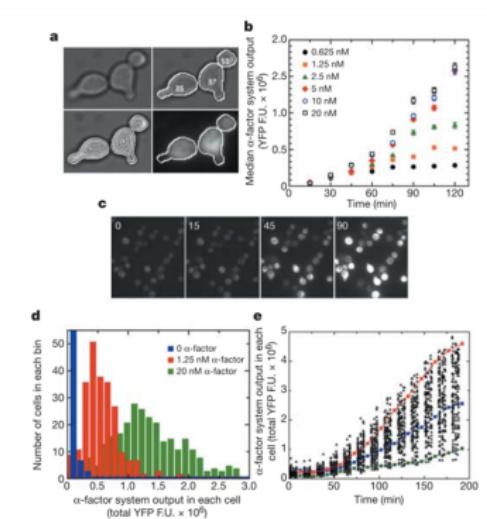
Operationally, intrinsic noise for a given gene may be defined as the extent to which the activities of two identical copies of that gene, in the same intracellular environment, fail to correlate.

Assuming each cell has the same number of components:
Intrinsic: variations within the same cell
Extrinsic: variations between cells.



Elowitz, M. B., Levine, a J., Siggia, E. D. and Swain, P. S. Stochastic gene expression in a single cell. *Science* (80-). 297, 1183–1186 (2002).

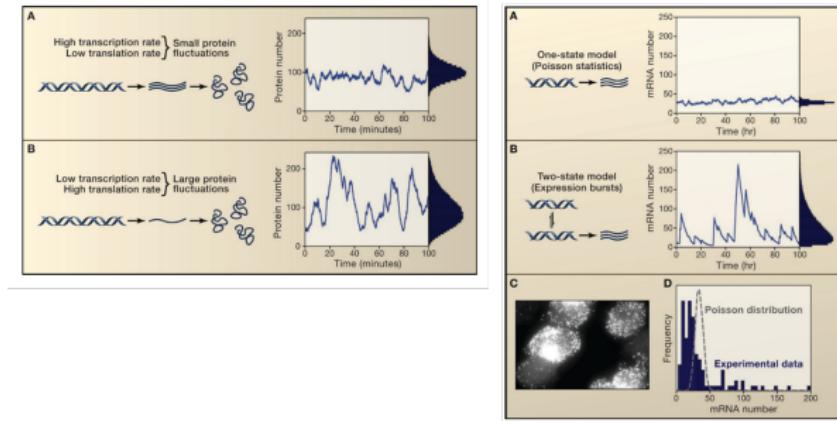
¿Cómo se modulan las distribuciones?



"inhibir a la molécula X aumenta el ruido"
(\rightarrow feedback negativo)

Colman-lerner, A. et al. Regulated cell-to-cell variation in a cell-fate decision system. Nature 437, (2005).

¿De dónde salen las distribuciones? (¿de qué tipo de topologías regulatorias?)



Raj, A. and van Oudenaarden, A. Nature, Nurture, or Chance: Stochastic Gene Expression and Its Consequences. Cell 135, 216–226 (2008).

Modulación de distribuciones (Biología sintética)

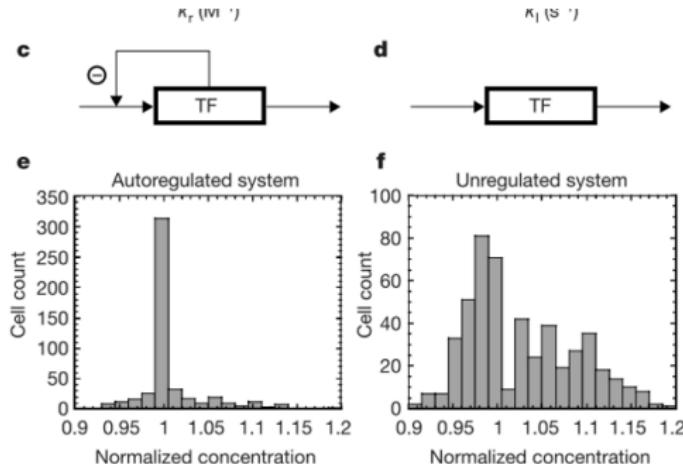


Figure 1 Stability properties of gene circuits. **a,b**, For calculating the value of relative

Becskei, a y Serrano, L. Engineering stability in gene networks by autoregulation. Nature 405, 590–593 (2000).

¡Robustez!

Importancia de las colas largas.

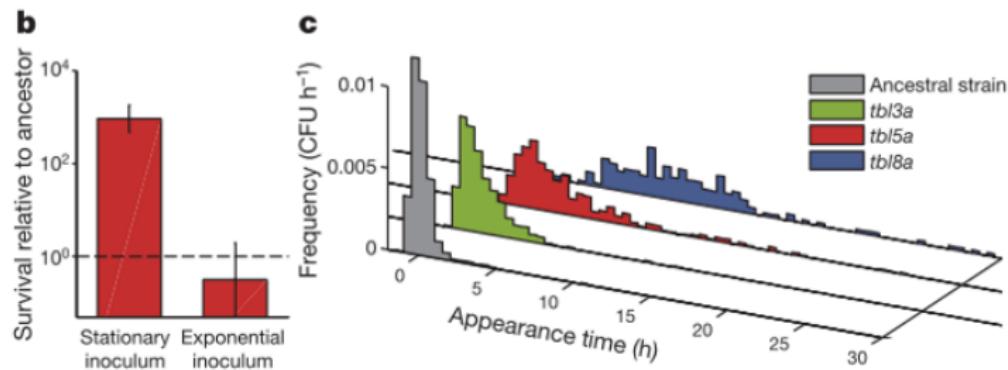
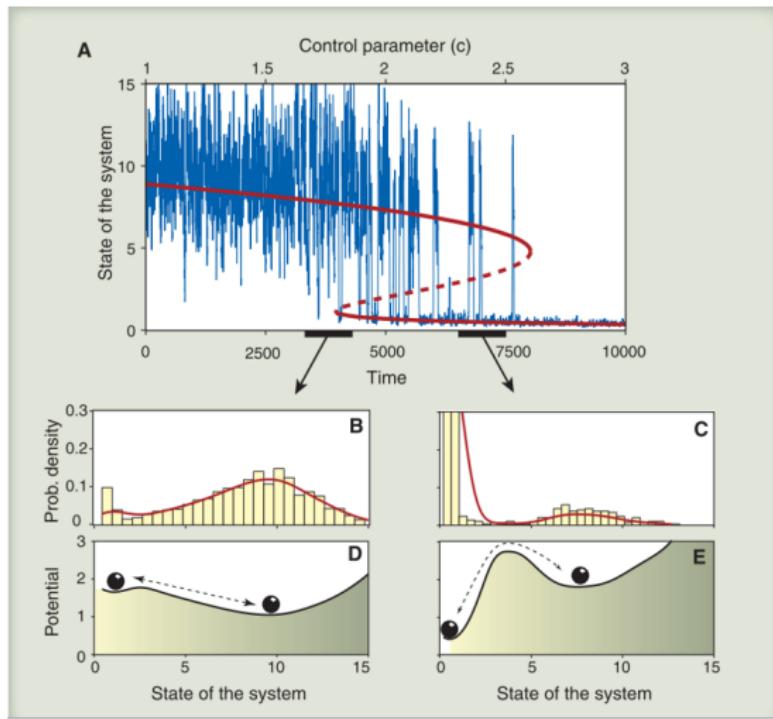


Figure 2 | Changes in the single-cell lag-time distributions underlie antibiotic tolerance. a, Phase-contrast images of time-lapse microscopy of

Fridman, O., Goldberg, A., Ronin, I., Shoresh, N. and Balaban, N. Q. Optimization of lag time underlies antibiotic tolerance in evolved bacterial populations. *Nature* 513, 418–421 (2014).

Marcadores estadísticos para predicción de catástrofes.



Scheffer, M. et al. Anticipating critical transitions. Science (80-.). 338, 344–348 (2012).

A modelar se ha dicho.

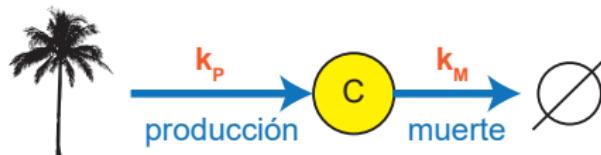
Idea general

Generaremos ahora familias de soluciones: corresponden a individuos en una población.
Se trata de eventos, i.e. realizaciones de un proceso estocástico. Colectivamente, generan
Distribuciones poblacionales

Wilkinson, D. J. Stochastic Modelling for Systems Biology. (Chapman and Hall, 2006).

Un ejemplo sencillo (lineal)

Producción y degradación.



¿cuál sería el modelo determinista?

$$\boxed{dC(t)/dt = +K_p - K_m \cdot C(t)}$$

Hint: esto guarda relación con el Ej. 2 EDH

El sistema determinista

$$\frac{dx}{dt} = k_p - xk_d \quad (21)$$

Conocemos ya varias cosas:

- Su punto de equilibrio:

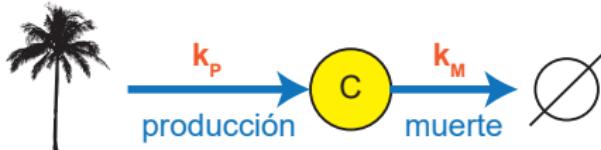
$$x_{ss} = k_p / k_d \quad (22)$$

(ustedes díganme por qué)

- Su solución analítica (disculpen, no lo vimos, pero al ser lineal esta solución \exists y es fácil encontrarla - y bueno, siempre podemos recurrir a un método numérico)

$$x(t) = k_p - e^{-k_d t} \times (k_p - k_d * x(0))k_d \quad (23)$$

, incluyendo su solución analítica

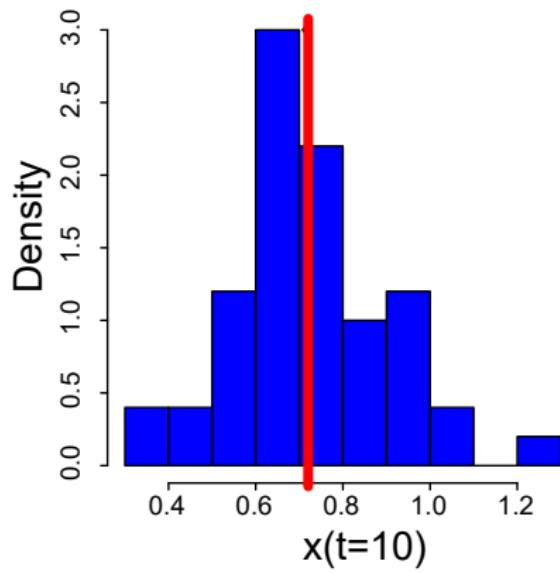
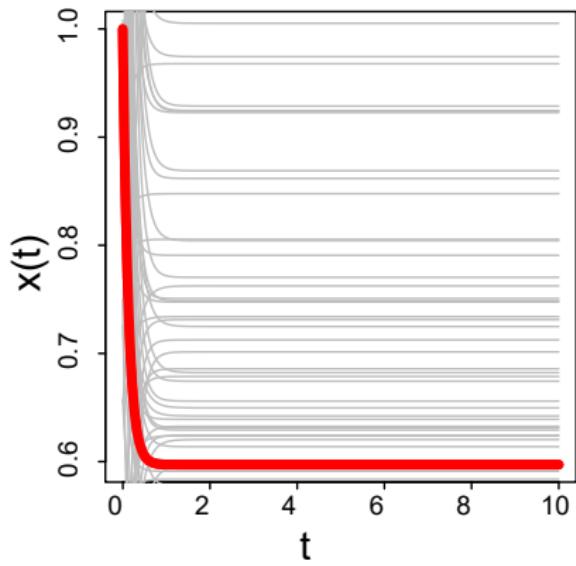


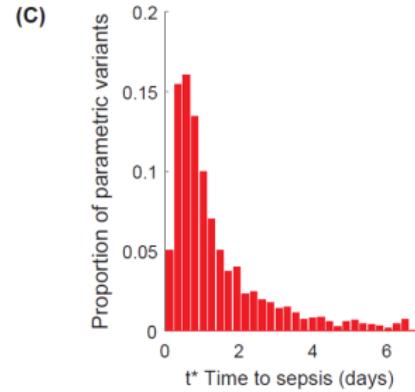
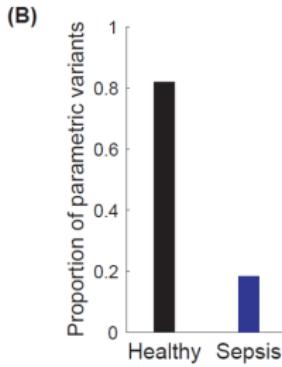
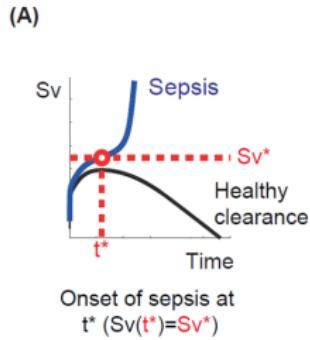
Ruido extrínseco

Construimos la distribución de x_{ss} (o $x(t_n)$) por medio de muestrear parámetros (y condiciones iniciales) de una distribución.

`Extrinsic_noise.R`

```
library(deSolve)
cocos <- function(t, X, parms){dX= kP-X*kD
list(dX)}
kP_nominal=5; kD_nominal=7; x0_nominal=1;
tspan =seq(from = 0, to = 10, by = 0.01)
iterations=50
x_t_family=matrix(data=NA, nrow=length(tspan), ncol = iterations)
for (i in 1:iterations){
  kP=rnorm(1, mean=kP_nominal, sd=1); kD=rnorm(1,
    mean=kD_nominal, sd=1)
  x0=rnorm(1, mean=x0_nominal, sd=1); parms=c(kP, kD)
  x= ode(y = x0, times = tspan, func = cocos, parms = parms)
  x_t_family[,i]=x[,2]
  lines(x[,1], x[,2], col="grey", type="l", lwd=1) }# end for
  iteraciones
lines(x_n[,1], x_n[,2], col="red", type="l", lwd=5,
      ylab="cocos", xlab="time" )
hist(x_t_family[1001,], freq=FALSE, col="blue", main=" ",
      xlab="x(t=10)")
points(kP_nominal/      kD_nominal, 3)
```





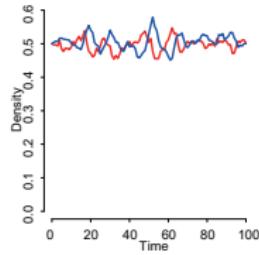
Domínguez-Hüttlinger, E., Boon, N. J., Clarke, T. B. and Tanaka, R. J. Mathematical Modeling of *Streptococcus pneumoniae* Colonization, Invasive Infection and Treatment. *Front. Physiol.* 8, 1–14 (2017).

Ruido aditivo

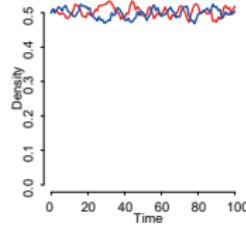
ALgoritmo de Euler-Maruyama (pasitos pequeños + muestreo de una variable distribuída gausianamente) GrindR_additive_noise_notes.R
(Lotka-Volterra)

```
# Run or Source Grind.R
model <- function(t, state, parms) {
  with(as.list(c(state,parms)), {
    dR <- r*R*(1 - R/K) - a*R*N
    dN <- c*a*R*N - delta*N
    return(list(c(dR, dN))) })
}
p <- c(r=1,K=1,a=1,c=1,delta=0.5) # p is a named vector of
parameters
s <- c(R=1,N=0.01) # s is the state
##### ADD GAUSSIAN NOISE TO BOTH VARIABLES #####
# START FROM THE EQUILIBRIUM STATE
f <- newton(c(R=0.5,N=0.5))
X=run(state=f,after="state<-state+rnorm(2,mean=0,sd=0.01)",
      legend=FALSE) #,ymax=1)
#Note that rnorm(2,0,0.01) provides two #random values, that are
added to the two variables, respectively.
iterations=50
# prealoca la matrix para guardar los resultados de las
simulaciones
x_t_family=matrix(data=NA, nrow=iterations, ncol = 2)
for (i in 1:iterations){
```

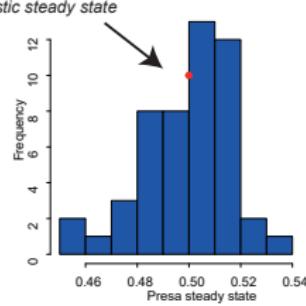
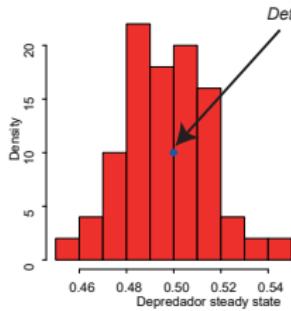
Iteration 1



Iteration 2



Final-time distribution (50 iterations)



Ruido intrínseco:

- Incluso individuos (genéticamente) **idénticos (parámetros y condiciones iniciales)** pueden diferir fenotípicamente.
- Las reacciones (procesos) son, en esencia, **eventos probabilísticos**, que ocurren con determinada **probabilidad**
- Volvemos a **discretizar** \bar{x} , y nos enfocamos en cómo cambia el **número de individuos** en cada (sub)población.
- Queremos conocer la **probabilidad de que haya x individuos/moléculas de X al tiempo t_n , para $x \in 0, 1, \dots, \mathbb{N}$ y para $t \in \mathbb{R}^+$**
- Ecuación Maestra, simulada de manera exacta con el **Algoritmo de Gillespie**

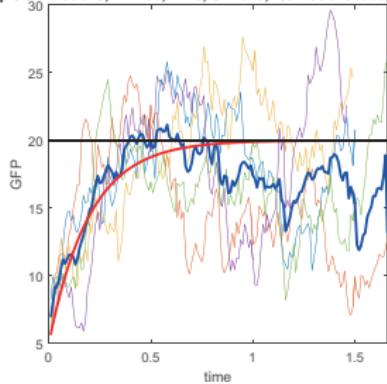
Wilkinson, D. J. Stochastic Modelling for Systems Biology. (Chapman and Hall, 2006).

Ruido intrínseco: ALgoritmo de Gillespie

GFP_gillespie_Notas.m

```
1 k1=100; k2=5; th=[k1,k2]; %parameters (rate constants)
2 h=@(y, th)[th(1), th(2)*y]; % Hazard functions
3 x0=5; n=300;% #IC; number of stepss
4 tt=0; % # initialize time
5 tvec=zeros(1,n); % # create a vector for the time, n number of
   realizations
6 xvec=zeros(1,n); % # vector for state variable
7 for i=1:1:n
8     totH= sum(h(x, th));%# total hazard
9     tt=tt+log(1/rand).*(1/ totH); %sample time to next event
    (Poisson process: waiting times exponentially distributed)
10    prob_reac=h(x, th)./totH; % choose a reaction to occur
11    if rand<=prob_reac(1) % choose first reaction
12        %# update state vector
13        x=x+1; % # GFP formed
14    else
15        x=x-1; % # decay
16    end
```

Gillespie simulations, $k_1=100$, $k_2=5$, GFP0=5, realizations=300, iterations=5

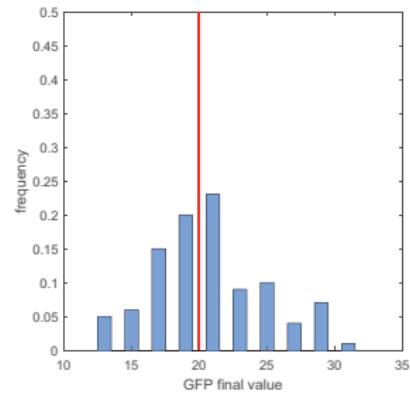
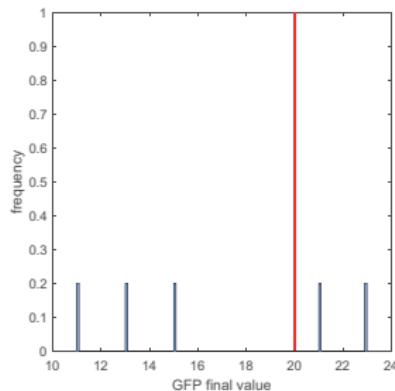
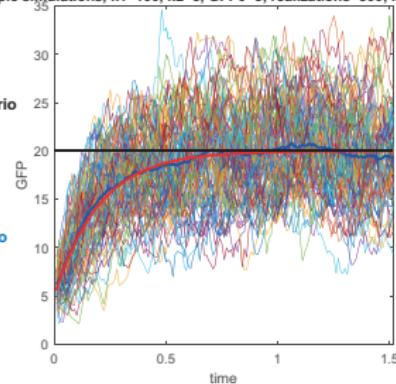


Gillespie simulations, $k_1=100$, $k_2=5$, GFP0=5, realizations=300, iterations=100

Estado estacionario determinista

ODE determinista

Promedio dinámico



En R

ALgoritmo de Gillespie GFP_Gillespie_Nota.r

```
1 IC=1; c1=100; c2=5; th=c(c1,c2); n=50; # Parameters / settings
2 h=function(y, th){return(c(th[1], th[2]*y))} # Hazard functions
3 # Gillespie algorithm
4 gillespieGFp <- function(IC, th, h, n)
5 {v=length(th) # number of reactions (IN THIS CASE: same as
6   number of kinetic parameters)
7 tt=0; x=IC; tvec=vector("numeric",n); xvec=vector("numeric", n)
8   # matrix for the u variables of the system
9   for (i in 1:n) {
10     totH= sum(h(x, th))# total hazard
11     tt=tt+rexp(1,totH) # sample time to next event from exp
12       probability distribution
13     j=sample(v,1, prob=h(x, th)) # choose a reaction to occur
14     # update state vector
15     if ( j==1) {x=x+1} # production
16     else # j==2
17       x=x-1 # degradation
18     # done, just fill in the vectors:
```



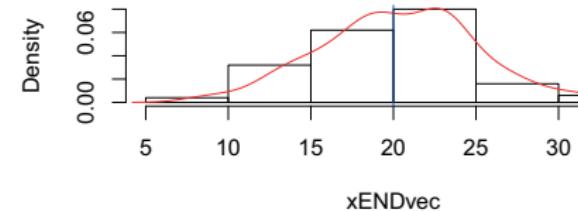
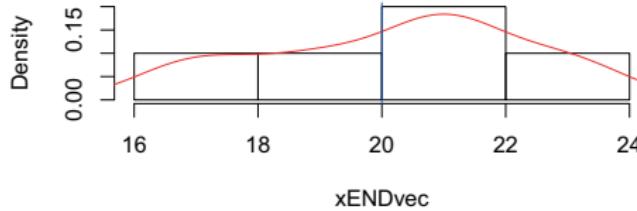
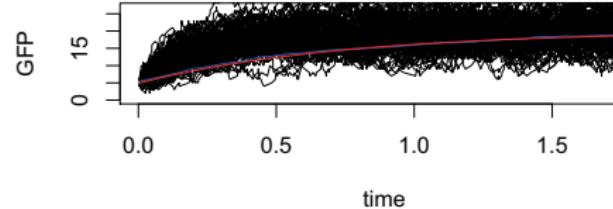
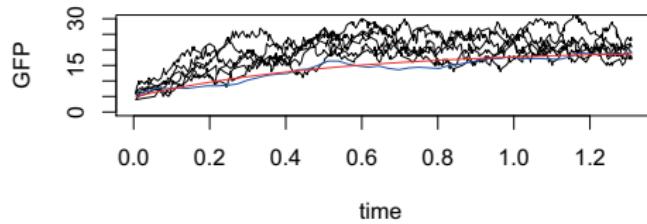


Figure: .. y en R.

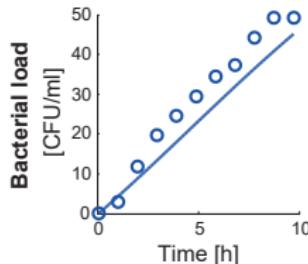
Recapitulación

De la biología descriptiva a la predictiva

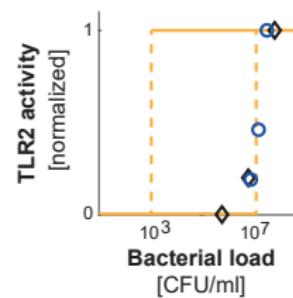


¿De dónde salen los patrones observados?

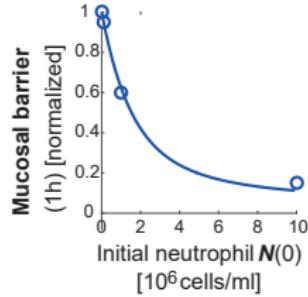
(A)



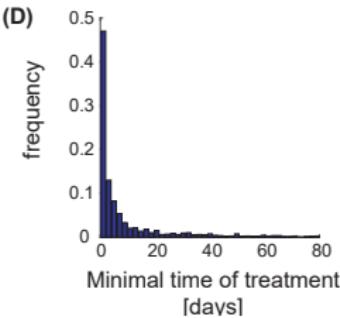
(B)



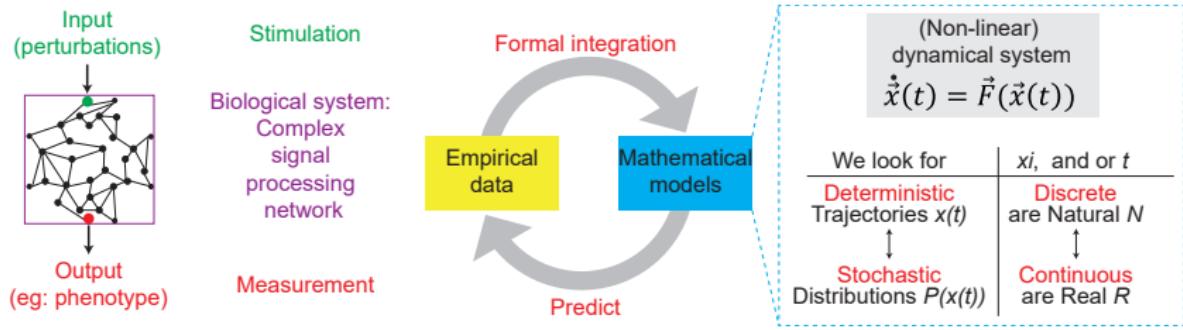
(C)



(D)

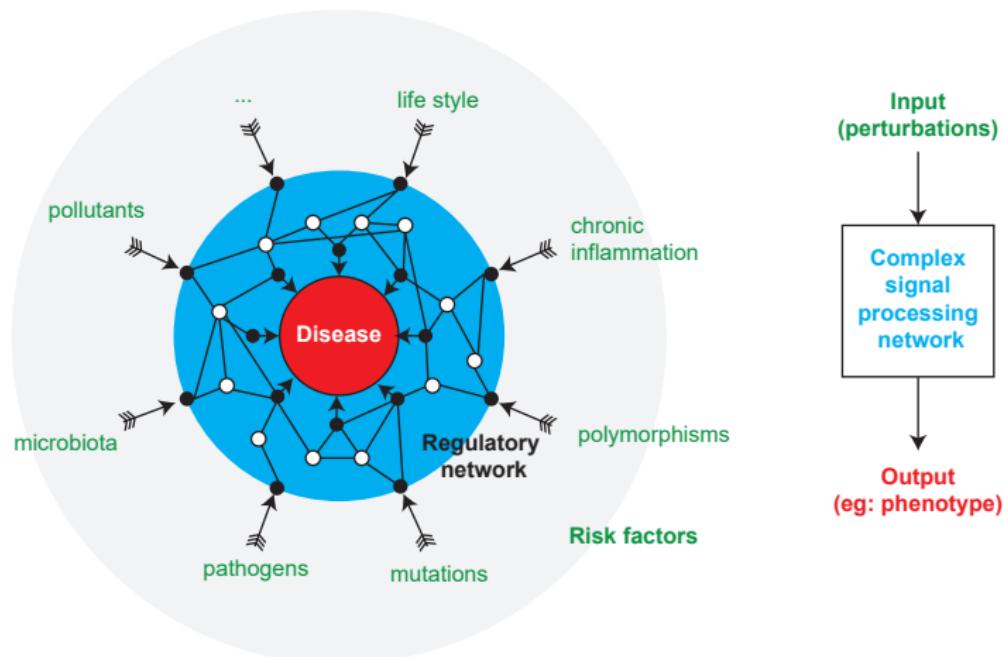


Biología de sistemas



Booleanos estocásticos y deterministas, ecuaciones diferenciales ordinarias y estocásticas, algoritmo de Gillespie.

Para predecir la respuesta del sistema a perturbaciones



Análisis de mutantes, análisis de robustez, análisis de sensibilidad paramétrica, evaluación de efectos de ruido intrínseco / extrínseco / estructural...

Ruido

- Intrínseco: *Chemical Master Equation* (algoritmo de Gillespie)
- Extrínseco (muestrear parámetros y condiciones iniciales de distribuciones)
- Estructural (ruido aditivo)

Stochastic differential equations

¿de dónde salen las distribuciones?

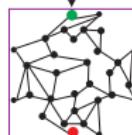
Trabajo en sus propios proyectos

Objetivo

Proponer una estrategia de investigación / análisis para abordar y responder alguna pregunta de investigación (ej. de su tesis)

1) Sketch the net

Input
(perturbations)



Output
(measurables)

- nodes:
- edges:
- input:
- output:

2) Select the formalism

And draft the system of equations

(Non-linear)
dynamical system

$$\dot{\vec{x}}(t) = \vec{F}(\vec{x}(t))$$

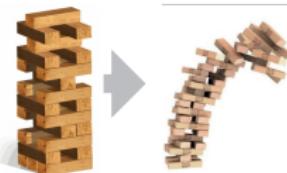
We look for

Deterministic
Trajectories $x(t)$

Stochastic
Distributions $P(x(t))$

- select one (ODEs, SDEs, boolean deterministic / stochastic)
- justify your choice

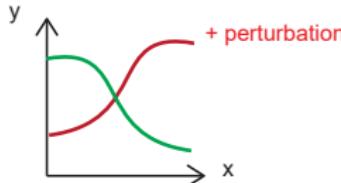
3) Design the dry experiment



- Which nominal behaviour is expected?

- Which perturbations will alter the system?

4) Draft your expected results



- What is x , what is y , what is the perturbation?
- How would your graph look in an ideal world?
- ... in a real world (with noise and experimental error)?
- in a dystopian world in which your hypothesis is wrong?

(1) Plantear la red de interacciones

A considerar:

- Nodos, interacciones
- Medibles
- Certezas vs certidumbres
- tipos de experimentos
- Perturbaciones

Output: Un dibujo de una red.

(2) Formalización

¿Qué formalismo matemático es adecuado para modelar tu red, y por qué?

"Systems biology is about making choices. The important part is to know how justify these choices: It's about conscientious decision-making."

Considera:

- Número de variables
- ¿Datos cualitativos o cuantitativos?
- Resolución temporal
- ¿Conocemos la distribución de los datos?
- ¿Qué predicciones nos importan? ¿estructurales o cuantitativas?

Output : Un formalismo (¡justificado!). (+ primer esbozo del modelo)

(3) ¿Qué análisis queremos hacer?

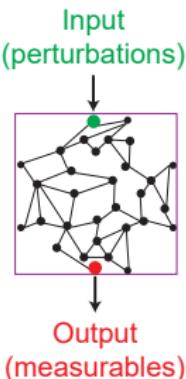
¿cuál es la pregunta, y cómo formalizarla? ¿su hipótesis se puede evaluar con análisis de perturbaciones?

- **Mutantes** (predecir efectos de alteraciones estructurales)
- **Bifurcaciones** (predecir efectos de alteraciones cuantitativas)
- **Análisis de robustez**
- **Análisis de sensibilidad paramétrica**
- **Análisis de optimización**
- *Simulación de modelos estocásticos bifurcantes*
- **Optimización paramétrica**

(4) Resultados esperados

Nuevamente tomen una hoja o varias hojas de papel. Ahora, imagínense un mundo ideal en el que todo sucede como lo planean, y en donde todas sus hipótesis son ciertas. ¿Qué gráfica obtendrían? Hagan un esbozo de esta gráfica esperada e ideal. (en el mundo paralelo: ¿cómo se verían las simulaciones del modelo que falsean su hipótesis?).

1) Sketch the net



- nodes:
- edges:
- input:
- output:

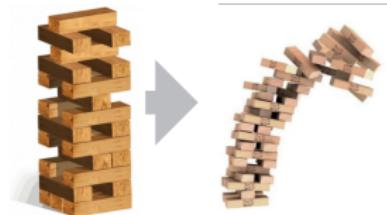
2) Select the formalism

And draft the system of equations

(Non-linear)
dynamical system
 $\dot{\vec{x}}(t) = \vec{F}(\vec{x}(t))$

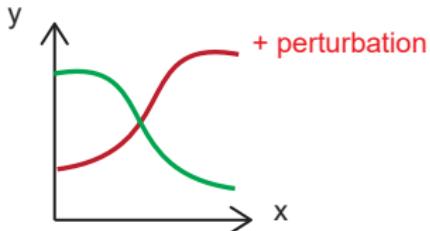
We look for	x_i , and or t
Deterministic Trajectories $x(t)$	Discrete are Natural N
Stochastic Distributions $P(x(t))$	Continuous are Real R
-select one (ODEs, SDEs, boolean deterministic / stochastic)	
-justify your choice	

3) Design the dry experiment



- Which nominal behaviour is expected?
- Which perturbations will alter the system?

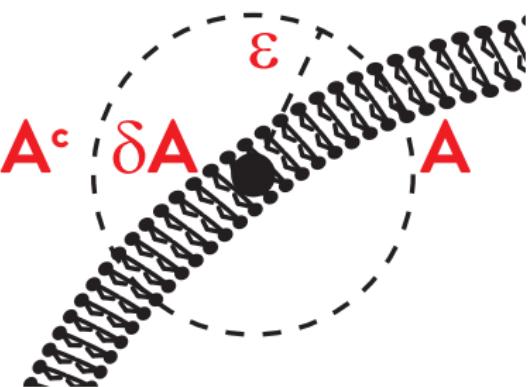
4) Draft your expected results



- What is x , what is y , what is the perturbation?
- How would your graph look in an ideal world?
- ... in a real world (with noise and experimental error)?
- in a dystopian world in which your hypothesis is wrong?

Artículos a exponer

- <http://www.icsb2018-france.com/program/invited-speakers>
- <https://www.sbhdb Berlin.org/speakers>



Systems Biology

IIB - UNAM