

# Modelación Estadística

Charlas de Acercamiento ICMAT



Departamento de Matemática  
UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA



# Estructura de la presentación

0. Presentación del grupo de Estadística.
1. Esquema de modelamiento estadístico.
2. Cursos del área de estadística.
3. Posibles tópicos de investigación.
4. Alumnos y ex-alumnos asociados a la línea.
5. Publicaciones científicas.



## Modelación Estadística: Académicos



(a) Alfredo Alegría



(b) Francisco Cuevas



(c) Felipe Osorio



(d) Ronny Vallejos



# Modelación Estadística: Alfredo Alegría<sup>1</sup>



- ▶ Ph.D. Mathematics, PUCV-UTFSM-UV, Chile (supervisor: Emilio Porcu).
- ▶ Áreas de investigación:  
**Multivariate spatial statistics,  
Geostatistics for large datasets,  
Non-gaussian random fields.**

- ▶ **Red de Colaboración:** Emilio Porcu, Peter Diggle (Reino Unido), Jorge Mateu (España), Reinhard Furrer (Suiza), Stefano Castruccio (USA), Moreno Bevilacqua, Xavier Emery (Chile).
- ▶ **Trabajos relevantes:** Computational Statistics & Data Analysis, Electronic Journal of Statistics, Environmetrics, International Statistical Review, Journal of Multivariate Analysis, SIAM Journal on Scientific Computing, Spatial Statistics, Statistics and Computing.
- ▶ Proyectos FONDECYT.
- ▶ Postdoctorado en la Universidad de Newcastle, UK.

---

<sup>1</sup>Página web: <https://sites.google.com/site/alfredoalegrijimenez/>



# Modelación Estadística: Francisco Cuevas<sup>2</sup>



- ▶ Ph.D. Mathematics and Physics, Ålborg University Denmark, and PUCV-UTFSM-UV, (supervisor: Jesper Møller).
- ▶ Áreas de investigación:  
**Multivariate spatial statistics,**  
**Point patterns,**  
**Functional data.**

- ▶ **Red de Colaboración:** Peter Diggle (Reino Unido), Marie-Helene Descary (Canadá), Jean-François Coeurjolly (Francia), Jesper Møller, Rasmus Waagepetersen, Christophe Biscio (Dinamarca), Moreno Bevilacqua (Chile).
- ▶ **Trabajos relevantes:** Biometrika, Environmentrics, Journal of Nonparametric Statistics, Spatial Statistics, Statistics and Computing.
- ▶ Proyecto ANID Postdoctorado.
- ▶ Postdoctorado en Université du Québec à Montréal, Montreal, Canadá.
- ▶ Miembro del centro AC3E.

---

<sup>2</sup>Página web: <https://fcocuevas87.github.io>



# Modelación Estadística: Felipe Osorio<sup>3</sup>



- ▶ D.Sc. Statistics, Universidade de São Paulo, Brasil.  
(supervisor: Gilberto A. Paula).
- ▶ Áreas de investigación:  
**Modelos para datos longitudinales,**  
**Diagnóstico de influencia,**  
**Funciones de inferencia.**
- ▶ Red de Colaboración: Gilberto A. Paula, Cibele Russo (Brasil), Manuel Galea (Chile), Federico Crudu (Italia).
- ▶ Trabajos relevantes: Annals of the Institute of Statistical Mathematics, Biometrical Journal, Computational Statistics & Data Analysis, Economics Letters, Signal Image and Video Processing, Spatial Statistics, Statistical Papers, Statistics and Computing.
- ▶ Proyectos FONDECYT, de cooperación internacional (PROSUL, CNPq).
- ▶ Creador de paquetes contribuídos a R (fastmatrix, heavy, L1pack, SpatialPack).
- ▶ Editor de la revista *Chilean Journal of Statistics*.

---

<sup>3</sup>Página web: <http://fosorios.mat.utfsm.cl>



# Modelación Estadística: Ronny Vallejos<sup>4</sup>

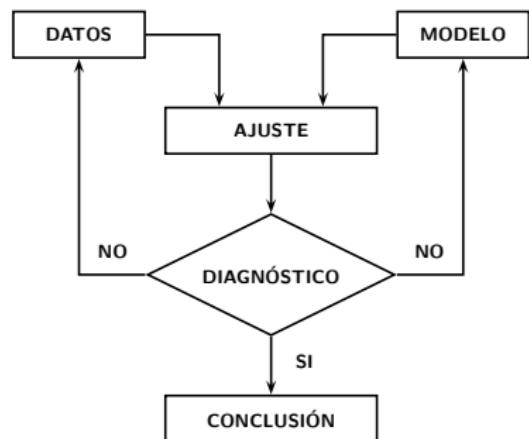


- ▶ Ph.D. Statistics, University of Maryland Baltimore County, USA. (supervisor: Andrew L. Rukhin).
- ▶ Áreas de investigación:  
**Spatial statistics,**  
**Robust modelling,**  
**Statistical image modelling,**  
**Time series.**
- ▶ Red de Colaboración: Daniel Griffith, Aaron Ellison (USA), Silvia Ojeda, Oscar Bustos (Argentina), Hannah Buckley, Bradley Case (New Zealand).
- ▶ Trabajos relevantes: Chance, Electronic Journal of Statistics, Journal of Mathematical Imaging and Vision, Journal of Statistical Planning and Inference, Natural Resource Modeling, Spatial Statistics, Stochastic Environmental Research and Risk Assessment.
- ▶ Proyectos FONDECYT, de cooperación internacional (CECYT, Math-AmSud), PIA.
- ▶ Ex Editor en Jefe de la revista *Chilean Journal of Statistics*, miembro de los centros AM2V y AC3E.

<sup>4</sup>Página web: <http://rvallejos.mat.utfsm.cl>



# Esquema de Modelación Estadística



Recolección de datos: **Muestreo.**

Análisis exploratorio de datos.

Análisis Multivariado.

Técnicas de Regresión.

Series de Tiempo, entre (muchas) otras.

Inferencia Estadística.

Bondad de ajuste, técnicas gráficas.

Análisis de Sensibilidad.

Comunique sus resultados!



# Cursos de especialidad: Modelación Estadística

## Obligatorios:

- ▶ MAT-041: Probabilidad y Estadística
- ▶ MAT-263: Teoría de Probabilidades y Procesos Estocásticos.
- ▶ MAT-206: Inferencia Estadística.

## Complementarios:

- ▶ Minería de datos (ELO)
- ▶ Proc. imágenes digitales (ELO)
- ▶ Teoría de información (ELO)

## Especialidad:

- ▶ MAT-266: Análisis de regresión.
- ▶ MAT-267: Series de tiempo.
- ▶ MAT-269: Análisis multivariado.

- ▶ Base de datos (INF)
- ▶ Física computacional (FIS)
- ▶ Inteligencia artificial (INF)



## Objetivo:

Estudiar una variable de respuesta,  $y$  [asumida continua] como función de algunas variables explicativas o regresores,  $x_1, x_2, \dots$  [pueden ser discretas y/o continuas].



En ocasiones la relación funcional es conocida salvo algunos coeficientes (parámetros).

Es decir, la relación puede estar gobernada por un proceso físico o por leyes bien aceptadas, tal que:

$$Y \approx f(x_1, \dots, x_p; \beta),$$

en cuyo caso, el interés recae en estimar el vector de parámetros  $\beta = (\beta_1, \dots, \beta_p)^\top$ .



# MAT-266: Análisis de Regresión

Asumiremos variables aleatorias independientes  $Y_1, \dots, Y_n$ , tal que

$$Y_i = \mu_i + \epsilon_i, \quad E(\epsilon_i) = 0, \quad i = 1, \dots, n,$$

esto es,

respuesta = parte sistemática + error aleatorio

## Idea:

Se desea “**estructurar**” la función de media como

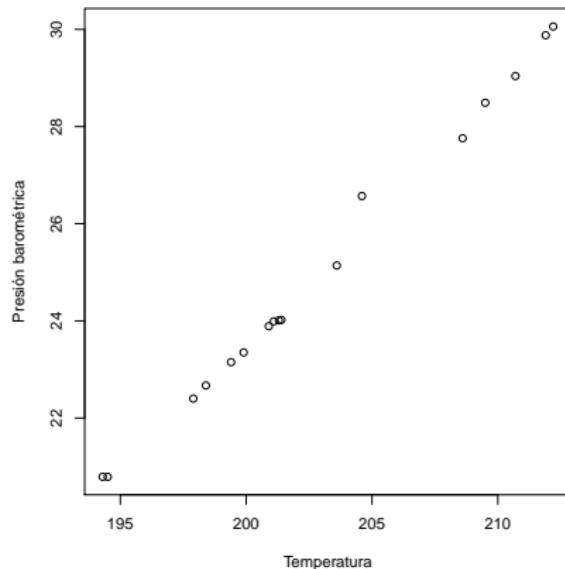
$$\mu_i = \mu_i(\beta), \quad i = 1, \dots, n,$$

con  $\beta \in \mathbb{R}^p$  y  $n \gg p$ .



## MAT-266: Análisis de Regresión

Presión barométrica en pulgadas de mercurio y temperatura de ebullición del agua en grados Fahrenheit para 17 diferentes altitudes (Forbes, 1857)<sup>5</sup>.



<sup>5</sup>Transactions of the Royal Society of Edinburgh 21, 235-243.



## MAT-266: Análisis de Regresión

Para describir la relación entre la temperatura y la media de la presión barométrica, podemos considerar:

$$\mu = \beta_0 + \beta_1 x,$$

note que

$$\mu = \mathbf{x}^\top \boldsymbol{\beta}, \quad \mathbf{x} = (1, x)^\top, \quad \boldsymbol{\beta} = (\beta_0, \beta_1)^\top,$$

y  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$  se denomina **predictor lineal**.

El conjunto de datos consiste del **vector de respuestas**.<sup>6</sup>

$$\mathbf{Y} = (Y_1, \dots, Y_n)^\top,$$

y una **matriz de diseño**  $n \times 2$

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^\top \\ \vdots \\ \mathbf{x}_n^\top \end{pmatrix}.$$

---

<sup>6</sup>Todos los vectores siempre serán **columna**.



## MAT-266: Análisis de Regresión

Para los datos de Forbes podemos considerar un modelo de regresión lineal definido como

$$Y_i \stackrel{\text{ind}}{\sim} N_1(\boldsymbol{x}_i^\top \boldsymbol{\beta}, \sigma^2), \quad i = 1, \dots, n,$$

o bien, escribir en forma compacta,<sup>7</sup>

$$\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n),$$

lo que lleva a,

$$E(Y_i) = \boldsymbol{x}_i^\top \boldsymbol{\beta}, \quad \text{var}(Y_i) = \sigma^2, \quad \text{Cov}(Y_i, Y_j) = 0,$$

para  $i, j = 1, \dots, n$ .

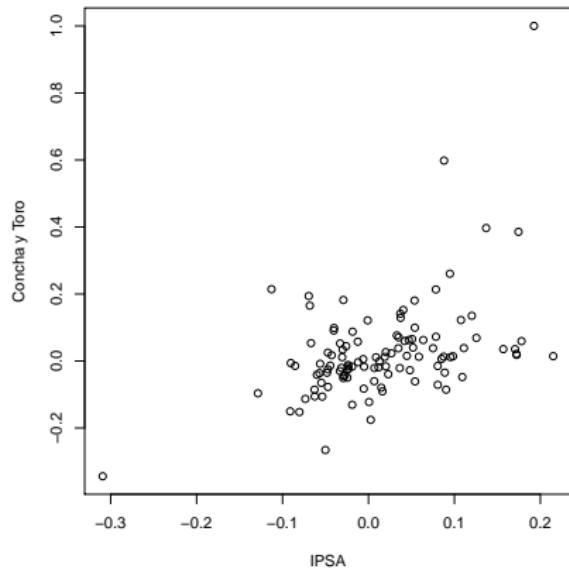
---

<sup>7</sup> Evidentemente también podemos escribir,  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$ ,  $\boldsymbol{\epsilon} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I})$ .



## MAT-266: Análisis de Regresión

Rentabilidades mensuales de Concha y Toro vs. IPSA, ajustados por bonos de interés del Banco Central entre marzo/1990 a abril/1999 (Osorio y Galea, 2006)<sup>8</sup>.



<sup>8</sup> Statistical Papers 47, 31-38



# MAT-266: Análisis de Regresión

Modelo CAPM (Valoración de Activos de Capital), (Sharpe, 1964)<sup>9</sup>

$$\mathbb{E}(r) = r_f + \beta(\mathbb{E}(r_m) - r_f),$$

usando datos observados, podemos escribir

$$R_t = \alpha + \beta \text{IPSA}_t + \epsilon_t, \quad t = 1, \dots, T.$$

Características del problema:

- ▶ Relación **lineal** entre las variables.
- ▶ Posibles periodos de **alta volatilidad**.

Hipótesis de interés:

- ▶  $H_0 : \beta > 1$  (**Amante del riesgo**).
- ▶  $H_0 : \beta = 1$  (**Neutral al riesgo**).
- ▶  $H_0 : \beta < 1$  (**Averso al riesgo**).



---

<sup>9</sup> Journal of Finance 19, 425-442

# MAT-266: Análisis de Regresión

- ▶ El requisito formal de la asignatura es [MAT-041: Probabilidad y Estadística](#)
- ▶ El curso se enfoca en estudiar:
  - Preliminares distribucionales.
  - Inferencia en el modelo de regresión lineal.
  - Análisis de los supuestos del modelo.
  - Identificación del mejor conjunto de regresores.
  - Alternativas a mínimos cuadrados.
  - Tópicos adicionales.



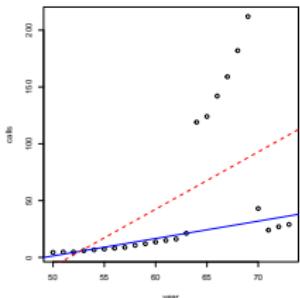
# MAT-266: Análisis de Regresión

Modelos lineales son los *bloques de construcción* para metodologías más complejas, tales como:

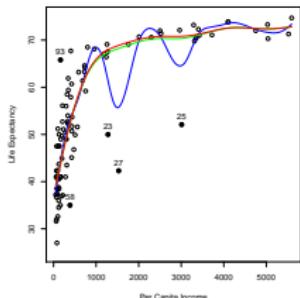
- ▶ Modelos lineales generalizados.
- ▶ Modelos no lineales.
- ▶ Modelos de regresión espacial.
- ▶ Regresión multivariada.
- ▶ Datos longitudinales, GMANOVA.
- ▶ Regresión semiparamétrica.
- ▶ Modelos con efectos mixtos.



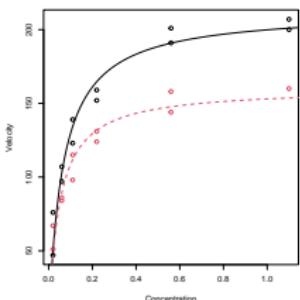
# MAT-266: Análisis de Regresión



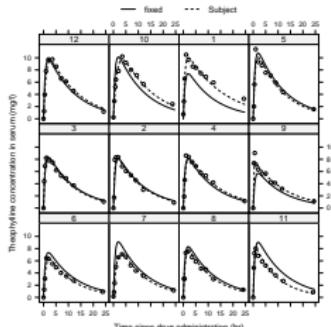
(a) regresión LAD



(b) splines penalizados



(c) regresión no-lineal



(d) modelos mixtos



## Objetivo:

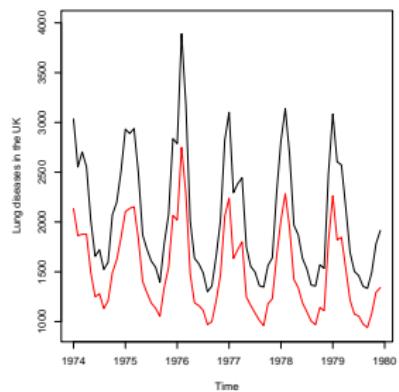
Se presentan procedimientos para modelar y hacer pronósticos en [series cronológicas](#).

Se describe métodos basados en suavizamiento exponencial, modelos ARMA y ARIMA así como modelos dinámicos y el filtro de Kalman univariado.

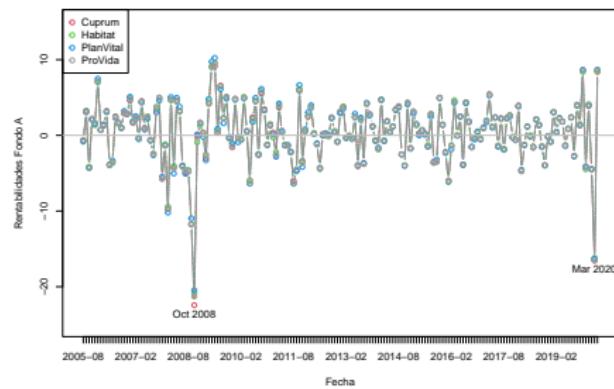
Se aborda la identificación, estimación y validación de modelos que consideran la presencia de correlación serial, para posteriormente aplicar la metodología en problemas de predicción o control.



# MAT-267: Series de Tiempo



(a) muertes en UK



(b) datos de AFPs



# MAT-267: Series de Tiempo

Algunos modelos que se describen en la asignatura son:

- Modelo AR( $p$ ):

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \cdots + \phi_p x_{t-p} + \epsilon_t,$$

- Modelo MA( $q$ ):

$$x_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \cdots + \theta_q \epsilon_{t-q}.$$

- Modelo ARMA( $p, q$ ):

$$x_t = \phi_1 x_{t-1} + \cdots + \phi_p x_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \cdots + \theta_q \epsilon_{t-q}.$$

- Modelo de espacio de estados:

$$\begin{aligned}y_t &= A_t z_t + u_t, \\z_t &= \Phi_{t-1} z_{t-1} + v_{t-1}.\end{aligned}$$

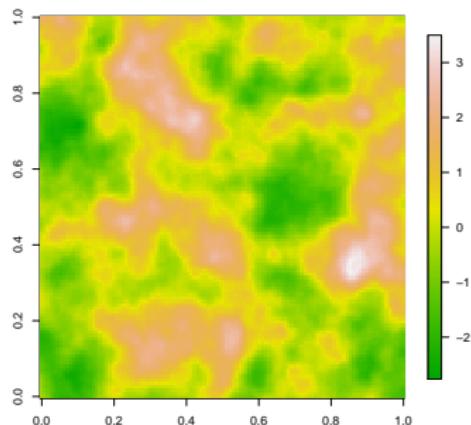


## MAT-267: Series de Tiempo

- ▶ El requisito de la asignatura es [MAT-266: Análisis de Regresión](#)
- ▶ El curso se enfoca en estudiar:
  - Métodos de suavizamiento exponencial.
  - Procesos estocásticos estacionarios.
  - Modelos ARMA, ARIMA y ARIMA estacional.
  - Análisis espectral.
  - Variables de estado y filtro de Kalman.
  - Tópicos adicionales.



# MAT-267: Series de Tiempo



(a) Kriging



(b) Imagen SAR



## Datos multivariados:

Tenemos una muestra aleatoria  $\mathbf{x}_1, \dots, \mathbf{x}_n$  donde para cada observación se ha medido  $p \geq 2$  variables (o características) de interés.<sup>10</sup>

Podemos disponer la información en una matriz de datos:

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_n^\top \end{pmatrix}.$$

## Observación:

Por simplicidad asumiremos que  $\mathbf{x}_1, \dots, \mathbf{x}_n$  son variables aleatorias independientes desde  $F_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  (con  $F_p$  común).

---

<sup>10</sup> Es decir,  $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})^\top$  es vector  $p$ -dimensional.



# MAT-269: Análisis Estadístico Multivariado

Desde 1988 el SIMCE evalua los **resultados de aprendizaje** de los estudiantes del sistema de educación chileno.

## Objetivos:

- ▶ Describir el **comportamiento del aprendizaje** de los estudiantes.
- ▶ Determinar si existe diferencias significativas entre el tipo de dependencia (municipal, subvencionado, particular).

## Características del problema:

- ▶ Mediciones de un **mismo individuo** (estudiante) **a través del tiempo** (4º y 8º básico, 2º medio).<sup>11</sup>
- ▶ Datos disponibles para los años 2007, 2011 y 2013, pruebas de Lenguaje y Matemáticas.

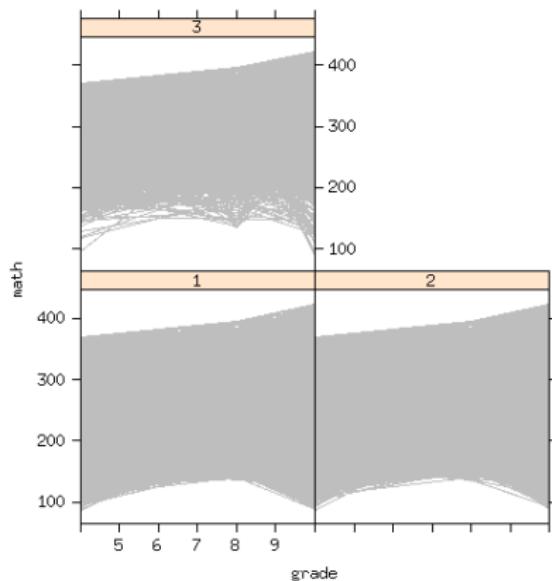
---

<sup>11</sup> Conocido como: **datos con estructura longitudinal**.



# MAT-269: Análisis Estadístico Multivariado

Perfiles individuales de los puntajes del SIMCE en matemáticas, organizados por tipo de dependencia.



# MAT-269: Análisis Estadístico Multivariado

## Características del problema:

- ▶ Aproximadamente 132K estudiantes para ser analizados (base de datos de **mediano porte**).
- ▶ Crecimiento lineal (cuadrático?) a través del tiempo.
- ▶ Igual número de mediciones por individuo (**datos balanceados**).

## Alternativas para análisis:

- ▶ Modelos con efectos-mixtos.
- ▶ Modelos multi-nivel.
- ▶ Modelo de curvas de crecimiento (GMANOVA).



# MAT-269: Análisis Estadístico Multivariado

Iris setosa



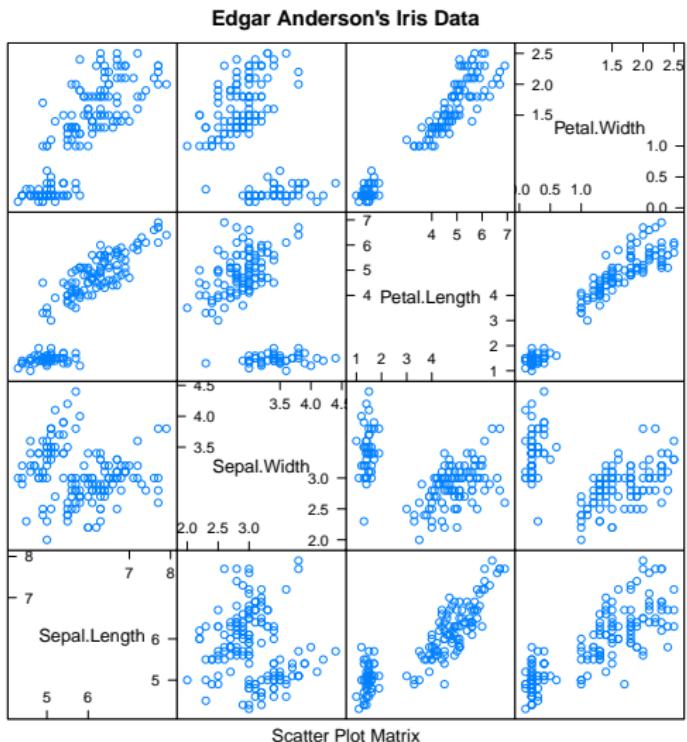
Iris versicolor



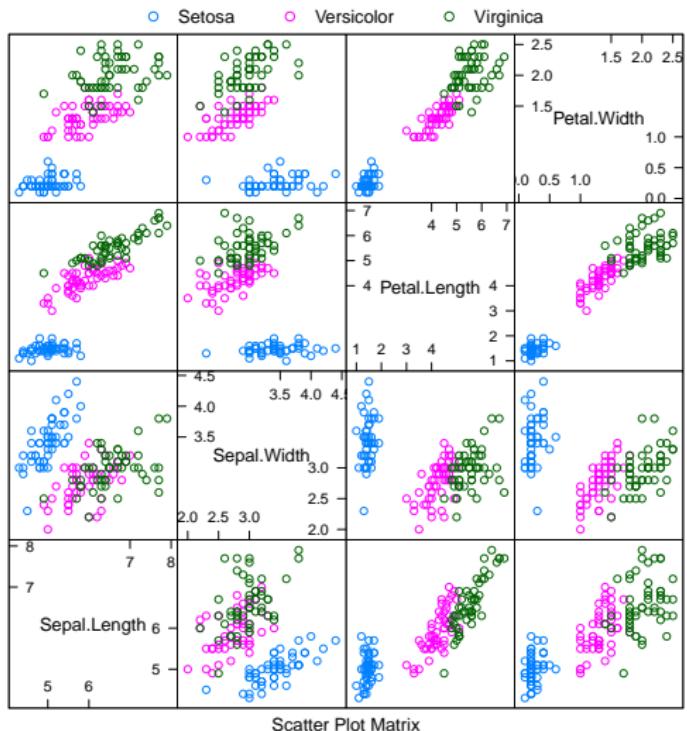
Iris virginica



# MAT-269: Análisis Estadístico Multivariado



# MAT-269: Análisis Estadístico Multivariado



# MAT-269: Análisis Estadístico Multivariado

Datos observados:

Mediciones (cm) del largo y ancho de los **sépalos** y el largo y ancho de **pétalos** para 50 flores desde 3 especies de **Iris** (setosa, virginica y versicolor).

Objetivo:

- ▶ Obtener una función que permita **discriminar** entre especies.
- ▶ Usando las medidas de una flor, **clasificarla** apropiadamente.

Características del problema:

- ▶ El análisis exploratorio revela una separación evidente en **2 grupos**.
- ▶ Técnicas más refinadas permiten identificar las 3 especies, p.ej.:
  - ▶ **Análisis discriminante**,
  - ▶ **Técnicas de clasificación** (Reconocimiento de patrones),
  - ▶ **Aprendizaje de máquina** (Máquinas de soporte vectorial, Data mining).

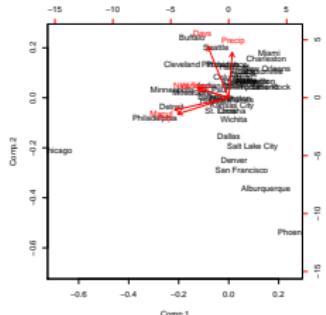


## MAT-269: Análisis Estadístico Multivariado

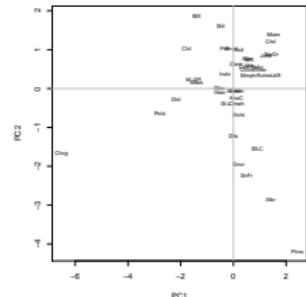
- ▶ El requisito de la asignatura es [MAT-266: Análisis de Regresión](#).
- ▶ Inferencia en análisis multivariado.
  - ▶ [Estimación y test de hipótesis](#) para una muestra aleatoria desde  $N_p(\mu, \Sigma)$ .
- ▶ Técnicas multivariadas.
  - ▶ Regresión multivariada y GMANOVA.
  - ▶ Análisis de componentes principales.
  - ▶ Análisis factorial.
  - ▶ Métodos de clasificación y agrupamiento.
- ▶ Tópicos adicionales.



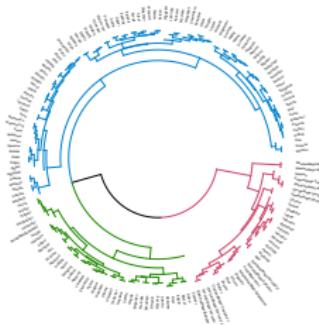
# MAT-269: Análisis Estadístico Multivariado



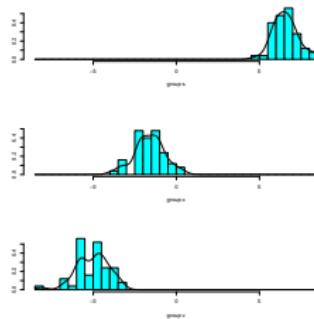
(a) biplot



(b) PCA



(c) cluster



(d) LDA



# Cursos de postgrado: Modelación Estadística

## Magíster en Matemática:

- ▶ MAT-431: Teoría de Probabilidades (Corresponde a MAT-263).
- ▶ MAT-460: Inferencia Estadística (Corresponde a MAT-206).
- ▶ MAT-420: Procesos Estocásticos.
- ▶ MAT-417: Series de Tiempo. (Corresponde a MAT-267).
- ▶ MAT-467: Modelos Espacio-Temporales.
- ▶ MAT-466: Modelos Lineales Generalizados.
- ▶ MAT-468: Simulación Estocástica.



# Reportes preliminares sobre el COVID-19



## Profesores:

- ▶ Pedro Gajardo (Optimización).
- ▶ Rodrigo Lecaros (Problemas Inversos).
- ▶ Felipe Osorio (Estadística).

## Estudiantes:

- ▶ Claudia Álvarez.
- ▶ José Fuentealba.
- ▶ Alonso Ogueda.
- ▶ Fabián Ramírez.
- ▶ Bernardo Recabarren.



# Reportes preliminares sobre el COVID-19

- ▶ El grupo ha realizado **8 reportes** preliminares sobre el COVID-19 en Chile.
- ▶ Se ha participado en **2 Workshops** sobre el modelamiento del brote de COVID-19.
- ▶ Colaboración con:
  - **Centro de Modelamiento Matemático (CMM)** de la Universidad de Chile.
  - **Centro de Epidemiología y Políticas de Salud (CEPS)** de la Universidad del Desarrollo.
- ▶ Objetivos de los reportes:
  - **Estimación de la demanda** de camas UCI (usando un modelo compartimentado).
  - Efectividad de las **cuarentenas dinámicas**.
  - Evaluación de la **reapertura de escuelas** (para algunas regiones).
  - Regresión segmentada para estimar los **tiempos de duplicación** del número de casos de COVID-19.



## Regresión segmentada para evaluar la efectividad de la cuarentena

### Método de regresión segmentada (Muggeo, 2003)<sup>12</sup>

Considere un GLM, donde  $\mu_i = E(Y_i)$ , con

$$g(\mu_i) = \mathbf{x}_i^\top \boldsymbol{\beta} + \delta_0 z_i + \delta_1 (z_i - \psi)_+,$$

donde  $\mathbf{x}_i$  denota covariables,  $\boldsymbol{\beta}$  son coeficientes de regresión,  $\delta_0$ ,  $\delta_1$  denotan la pendiente y el incremento de cada segmento, mientras que  $\psi$  indica el punto de cambio.

El procedimiento puede ser extendido para estimar  $K + 1$  regímenes, como:

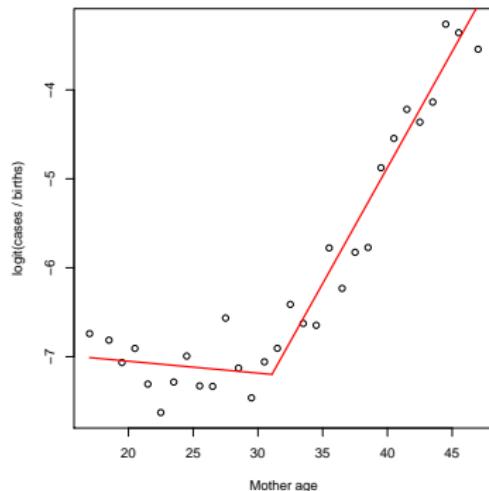
$$g(\mu_i) = \mathbf{x}_i^\top \boldsymbol{\beta} + \delta_0 z_i + \delta_1 (z_i - \psi_1)_+ + \cdots + \delta_K (z_i - \psi_K)_+.$$

---

<sup>12</sup>Statistics in Medicine 22, 3055-3071.



## Regresión segmentada para evaluar la efectividad de la cuarentena



- ▶ El método de estimación es basado en el uso de una **aproximación lineal**.
- ▶ La propuesta es bastante **más eficiente** que su contraparte basada en **búsqueda de grilla**.
- ▶ Podemos probar la **existencia de un punto de cambio** usando test de hipótesis.

$$H_0 : \delta_j(\psi_j) = 0, \quad j = 1, \dots, K.$$

- ▶ Método implementado en el paquete R: **segmented**.



## Regresión segmentada para evaluar la efectividad de la cuarentena

### Regresión segmentada para datos de COVID-19 (Muggeo et al., 2020)<sup>13</sup>

Sea  $Y_t$  el número acumulado de casos infectados en el día  $t = 1, 2, \dots$ . El modelo de **crecimiento exponencial**, lleva al modelo de regresión Poisson para  $\mu_t = E(Y_t)$ , como:

$$\log \mu_t = \beta_0 + \beta_1 t + \delta_1(t - \psi_1)_+ + \cdots + \delta_K(t - \psi_K)_+.$$

Es decir, tenemos  $K + 1$  regímenes, y

$$\beta_1, \quad \beta_2 = \beta_1 + \delta_1, \quad \dots, \quad \beta_{K+1} = \beta_1 + \sum_{k=1}^K \delta_k,$$

denota las pendientes para cada uno de los segmentos.

#### Observación:

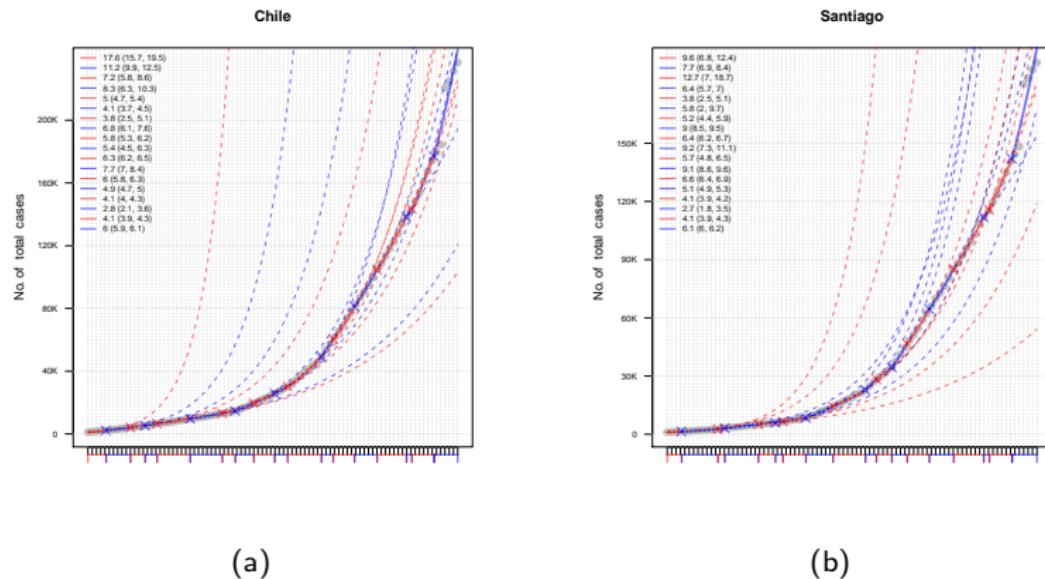
Basado en lo anterior podemos calcular las **tasas de crecimiento** y los **tiempos de duplicación**, como:

$$r_k = \exp(\beta_k) - 1, \quad d_k = \log(2)/\beta_k, \quad k = 1, \dots, K + 1.$$

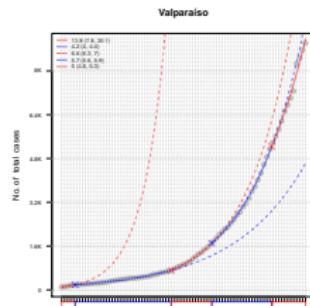
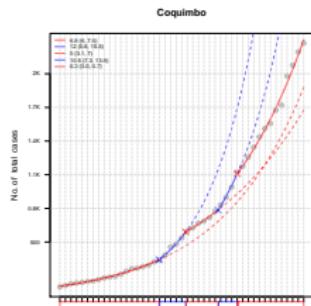


<sup>13</sup>doi: 10.13140/RG.2.2.32798.28485

# Regresión segmentada y puntos de cambio: Chile y RM

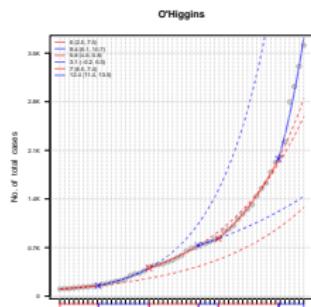


# Regresión segmentada y puntos de cambio: Coquimbo al Maule

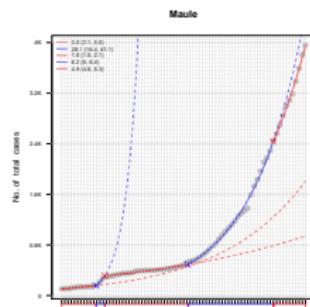


(a)

(b)



(c)



(d)



# Resumen de estimación<sup>14</sup>

Región	casos totales	número de segmentos	Tasa de crecimiento	Tiempos de duplicación	
Arica	1 325	3	1.7	3.8	40.10 18.50
Tarapacá	5 143	6	6.5	3.8	11.03 18.38
<b>Antofagasta</b>	<b>6 215</b>	<b>4</b>	<b>3.6</b>	<b>6.5</b>	<b>19.79 11.05</b>
Atacama	650	2	2.7	6.0	25.64 11.88
Coquimbo	2 273	5	10.5	6.3	6.93 11.38
<b>Valparaíso</b>	<b>9 014</b>	<b>5</b>	<b>5.7</b>	<b>5.0</b>	<b>12.46 14.08</b>
<b>Metropolitana</b>	<b>191 577</b>	<b>18</b>	<b>4.1</b>	<b>6.1</b>	<b>17.31 11.66</b>
O'Higgins	3 613	6	7.0	12.4	10.26 5.92
Maule	3 958	5	6.2	4.9	11.51 14.40
Ñuble	2 135	5	2.2	2.6	31.82 26.53
Biobío	4 658	8	3.9	6.7	18.23 10.76
<b>La Araucanía</b>	<b>2 920</b>	<b>6</b>	<b>1.8</b>	<b>1.0</b>	<b>37.87 71.63</b>
Los Ríos	589	3	1.2	2.9	58.20 24.64
Los Lagos	1 335	3	1.6	2.1	43.37 32.97
Aysén	28	3	0.3	3.9	198.90 18.12
Magallanes	1 315	3	0.6	2.4	120.42 28.85
<b>Chile</b>	<b>236 748</b>	<b>18</b>	<b>4.1</b>	<b>6.0</b>	<b>17.23 11.95</b>

<sup>14</sup> Descargados el día Sábado 20 de Junio 2020,  
URL: <https://github.com/MinCiencia/Datos-COVID19/tree/master/output/producto3>



# Estimación del SSIM

## Trabajo:

Osorio, F., Vallejos, R., Barraza, W., Ojeda, S., Landi, M.A. (2022). Statistical estimation of the structural similarity index for image quality assessment. *Signal, Image and Video Processing* **16**, 1035-1042.

Considere dos imágenes  $\mathbf{x}, \mathbf{y} \in \mathbb{R}_+^N$ , el coeficiente de similaridad estructural (SSIM) es dado por:

$$\text{SSIM}(\mathbf{x}, \mathbf{y}; \boldsymbol{\theta}) = l(\mathbf{x}, \mathbf{y})^\alpha \cdot c(\mathbf{x}, \mathbf{y})^\beta \cdot s(\mathbf{x}, \mathbf{y})^\gamma,$$

donde

$$l(\mathbf{x}, \mathbf{y}) = \frac{2\bar{x}\bar{y} + c_1}{\bar{x}^2 + \bar{y}^2 + c_1}, \quad c(\mathbf{x}, \mathbf{y}) = \frac{2s_x s_y + c_2}{s_x^2 + s_y^2 + c_2},$$

$$s(\mathbf{x}, \mathbf{y}) = \frac{s_{xy} + c_3}{s_x s_y + c_3}.$$

## Objetivo:

Basado en imágenes observadas  $\mathbf{x}$  e  $\mathbf{y}$ , estimar  $\boldsymbol{\theta} = (\alpha, \beta, \gamma)^\top$  y probar la hipótesis:

$$H_0 : \alpha = \beta = \gamma = 1.$$



# Estimación del SSIM

Se consideró un **modelo no-lineal heteroscedástico<sup>15</sup>** bajo el supuesto:

$$Z_i \sim N(\phi f_i(\boldsymbol{\theta}), f_i^2(\boldsymbol{\theta})g^2(\phi)), \quad i = 1, \dots, n,$$

donde

$$f_i(\boldsymbol{\theta}) = \text{SSIM}(\mathbf{x}_i, \mathbf{y}_i; \boldsymbol{\theta}), \quad g^2(\phi) = \phi^2(\phi^2 - 1),$$

corresponden a **funciones de media y de varianza** y  $Z_i = 1/\text{RMSE}(\mathbf{x}_i, \mathbf{y}_i)$ .

## Resultados:

- ▶ **Algoritmo de estimación:** Híbrido entre método secante multivariado (BFGS) con **pseudo-verosimilitud** (método de Brent).<sup>16</sup>
- ▶ **Test de hipótesis** usando el **estadístico gradiente** (Terrell, 2000).
- ▶ **Matriz de información de Fisher** y método eficiente para evaluar **función score**.
- ▶ **Experimento numérico** con **datos sintéticos** (desde base de datos USC-SIPI) y **datos desde la constelación de satélites ICEYE SAR**.

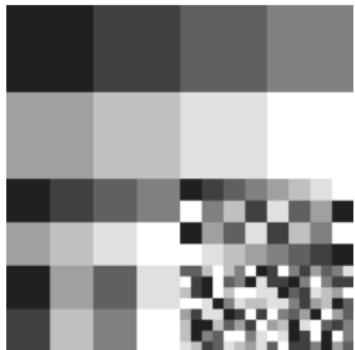
---

<sup>15</sup> Inspirado en el contexto de **funciones de producción** (Econometría).

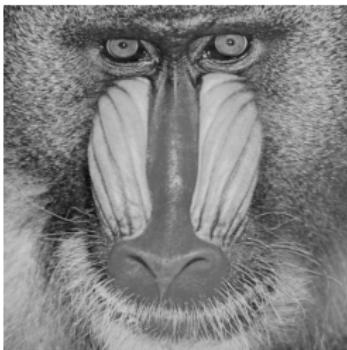
<sup>16</sup> Código C y R disponible en [github.com/faosorios/SSIM](https://github.com/faosorios/SSIM).



## Estimación del SSIM: estudio de simulación Monte Carlo<sup>19</sup>



(a) texmos2.S512



(b) Baboon



(c) Lenna

Imágenes de referencia<sup>17</sup> ( $\mathbf{x} \in \mathbb{R}_+^N$ ) fueron contaminadas con ruido multiplicativo<sup>18</sup> usando una distribución  $\text{Gamma}(L, L)$ , es decir,

$$\mathbf{y} = \mathbf{x} \cdot \mathbf{w}, \quad w_t \sim \text{Gamma}(L, L), \quad t = 1, \dots, N,$$

para  $L = 1, 2, 4, 8, 16$  y  $32$  looks. Para cada look 1,000 imágenes fueron construidas.

---

<sup>17</sup> Extraídas desde la base de imágenes USC-SIPI, URL: <http://sipi.usc.edu/database>

<sup>18</sup> Disponible en la función `imnoise` desde el paquete R `SpatialPack`.

<sup>19</sup> Se ajustaron 144 000 modelos (tiempo: 34 hrs, 40 min, 16 seg).



## Estimación del SSIM: contaminación de Lenna



(a)  $L = 1$



(b)  $L = 2$



(c)  $L = 4$



(d)  $L = 8$



(e)  $L = 16$



(f)  $L = 32$



## Estimación del SSIM: imágenes de Radar de Apertura Sintética (SAR)<sup>20</sup>



(a) Copeland



(b) Dam



(c) Corpus Christi



(d) Mississippi

<sup>20</sup> Constelación de satélites ICEYE SAR: <https://www.iceye.com/downloads/datasets>



## Estimación del SSIM: resultados con imágenes SAR

Copeland (4096 × 2560)				Corpus Christi (4096 × 2560)		
Filter	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}$	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}$
Lee	1.891	1.932	3.136	1.610	1.639	2.705
Enhanced Lee	1.691	1.722	2.987	1.600	1.626	2.512
Kuan	1.691	1.722	2.987	1.600	1.626	2.512

Dam (1200 × 1200)				Mississippi (4096 × 4096)		
Filter	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}$	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}$
Lee	1.000	1.000	1.000	1.591	1.623	2.670
Enhanced Lee	1.000	1.000	1.000	1.468	1.491	2.553
Kuan	1.000	1.000	1.000	1.468	1.491	2.553



## Estimación del SSIM: resultados con imágenes SAR<sup>21</sup>

Copeland (4096 × 2560)		Corpus Christi (4096 × 2560)		
Filter	SSIM		SSIM	
	Under $H_0$	Under $H_1$	Under $H_0$	Under $H_1$
Lee	0.680	0.326	0.828	0.614
Enhanced Lee	0.652	0.306	0.818	0.615
Kuan	0.652	0.306	0.818	0.615

Dam (1200 × 1200)		Mississippi (4096 × 4096)		
Filter	SSIM		SSIM	
	Under $H_0$	Under $H_1$	Under $H_0$	Under $H_1$
Lee	0.999	0.999	0.890	0.740
Enhanced Lee	0.999	0.999	0.884	0.737
Kuan	0.999	0.999	0.884	0.737

<sup>21</sup>Recuerde que  $H_0 : \alpha = \beta = \gamma = 1$ .



## Temas tentativos para tesis: Alfredo Alegría<sup>22</sup>



- ▶ Campos aleatorios para modelar datos espacio-temporales sobre grandes porciones del planeta.
- ▶ Funciones de covarianza cruzada flexibles y su aplicación en el análisis de datos espacio-temporales multivariados.
- ▶ Métodos de estimación y predicción para campos aleatorios no-gaussianos y/o para grandes conjuntos de datos.

---

<sup>22</sup>E-mail: [alfredo.alegria@usm.cl](mailto:alfredo.alegria@usm.cl)



# Temas tentativos para tesis: Francisco Cuevas<sup>23</sup>



- ▶ Alineamiento y registro de funciones.
- ▶ Aproximaciones Bayesianas computacionales para campos aleatorios.
- ▶ Regresión penalizada para patrones puntuales.

---

<sup>23</sup>E-mail: [francisco.cuevas@usm.cl](mailto:francisco.cuevas@usm.cl)



## Temas tentativos para tesis: Felipe Osorio<sup>24</sup>



- ▶ Diagnóstico de influencia en el contexto de estimación máximo  $Lq$ -verosímil.
- ▶ Probabilidad de concordancia entre dos sistemas de medición usando P-splines robustos.
- ▶ Probabilidad de concordancia para varios instrumentos de medición.

---

<sup>24</sup>E-mail: [felipe.osorios@usm.cl](mailto:felipe.osorios@usm.cl) (no olvidar la 's' !)



## Temas tentativos para tesis: Ronny Vallejos<sup>25</sup>



- ▶ Desarrollo de medidas de concordancia para datos espacio-temporales.
- ▶ Extensión de la probabilidad de concordancia para datos espaciales.
- ▶ Tamaño muestral efectivo para datos espacio-temporales.

---

<sup>25</sup>E-mail: [ronny.vallejos@usm.cl](mailto:ronny.vallejos@usm.cl)



# Modelación Estadística: Estudiantes de pregrado

- ▶ Nicolás Alfaro.
- ▶ Manuel Jara.
- ▶ Marcela Miranda.
- ▶ Eric Muñoz.
- ▶ Fabián Rubilar.
- ▶ Matías Sasso.
- ▶ Bastián Sepúlveda.
- ▶ Edgard González (2022).
- ▶ Sebastián Vera (2022).
- ▶ Pablo Huenchulao (2021).
- ▶ Gabriel Vidal (2021).
- ▶ Gabriel Molina (2020).
- ▶ Alberto Rubio (2019).
- ▶ Alexis Tapia (2019).
- ▶ Alonso Ogueda (2018).
- ▶ Francisco Alfaro (2017).
- ▶ Wilson Barraza (2017).
- ▶ Javier Pérez (2017).
- ▶ Ignacio Vásquez (2017).
- ▶ Ángelo Gárate (2016).
- ▶ Carlos Schwarzenberg (2016).
- ▶ Jean Paul Maidana (2015).
- ▶ Agustín Uribe (2015).
- ▶ Alfredo Alegría (2014).
- ▶ Claudio Henríquez (2014).
- ▶ Consuelo Moreno (2014).
- ▶ Jonathan Acosta (2013).
- ▶ Francisco Cuevas (2011).
- ▶ Danilo Pezo (2011).
- ▶ Jorge Littin (2006).



## Modelación Estadística: Estudiantes de postgrado

- ▶ John Gómez.
- ▶ Fabian Ramírez (2022).
- ▶ Alonso Ogueda (2021).
- ▶ Carlos Schwarzenberg (2021).
- ▶ Francisco Alfaro (2019).
- ▶ Javier Perez (2019).
- ▶ Sebastián Torres (2019).
- ▶ Ángelo Garate (2018).
- ▶ Jonathan Acosta (2017).
- ▶ Diego Mancilla (2014).
- ▶ Francisco Cuevas (2013).
- ▶ Danilo Pezo (2013).
- ▶ Paola Carvajal (2006).
- ▶ Ronny Vallejos (1999).



## Algunos trabajos recientes



**Cuevas, F., Coeurjolly, J.F., Descary, M.H. (2022+).**

Fast estimation of a convolution type model for the intensity of spatial point processes.  
*Spatial Statistics* (to appear).



**Osorio, F., Vallejos, R., Barraza, W., Ojeda, S., Landi, M. (2022).**

Statistical estimation of the structural similarity index for image quality assessment.  
*Signal, Image and Video Processing* **16**, 1035-1042.



**Vidal, G., Yuz, J., Vallejos, R., Osorio, F. (2022).**

Point-process modeling and divergence measures applied to the characterization of passenger flow patterns of a metro system.  
*IEEE Access* **10**, 26529-26540.



**Emery, X., Alegria, A. (2022).**

The Gauss hypergeometric covariance kernel for modeling second-order stationary random fields in Euclidean spaces: Its compact support, properties and spectral representation.  
*Stochastic Environmental Research and Risk Assessment* **36**, 2819-2834.



**Acosta, J., Alegria, A., Osorio, F., Vallejos, R. (2021).**

Assessing the effective sample size for large spatial datasets: A block likelihood approach.  
*Computational Statistics & Data Analysis* **162**, 107282.



**Alegria, A., Bissiri, P.G., Cleanthous, G., Porcu, E., White, P. (2021).**

Multivariate isotropic random fields on spheres: Nonparametric bayesian modeling and  $L^p$  fast approximations.

*Electronic Journal of Statistics* **1**, 2360-2392.



## Algunos trabajos recientes



**Alegría, A., Cuevas, F., Diggle, P., Porcu, E. (2021).**

The  $\mathcal{F}$ -family of covariance functions: A Matérn analogue for modeling random fields on spheres.

*Spatial Statistics* 43, 100512.



**Alegría, A., Emery, X., Porcu, E. (2021).**

Bivariate Matérn covariances with cross-dimple for modeling coregionalized variables.

*Spatial Statistics* 41, 100491.



**Emery, X., Alegría, A., Arroyo, D. (2021).**

Covariance models and simulation algorithm for stationary vector random fields on spheres crossed with Euclidean spaces.

*SIAM Journal on Scientific Computing* 43, A3114-A3134.



**Papaterra, M., Ojeda, S., Landi, M., Vallejos, R. (2021).**

Strategy for selecting a quality index for images.

*International Journal of Computer Information Systems and Industrial Management Applications* 13, 348-363.



**Vallejos, R., Acosta, J. (2021).**

Effective sample size for multivariate spatial processes with an application to soil contamination.

*Natural Resource Modeling* 34, e12322.



**Alegría, A. (2020).**

Cross-dimple in the cross-covariance functions of bivariate isotropic random fields on spheres.

*Stat* 9, e301.



# Algunos trabajos recientes



**Alegría, A., Cuevas, F. (2020).**

Karhunen-Loève expansions for axially symmetric gaussian processes: Modeling strategies and  $L^2$  approximations.

*Stochastic Environmental Research and Risk Assessment* 34, 1953-1965.



**Alegría, A., Emery, X., Lantuéjoul, C. (2020).**

The turning arcs: A computationally efficient algorithm to simulate isotropic vector-valued gaussian random fields on the d-sphere.

*Statistics and Computing* 30, 1403-1418.



**Choiruddin, A., Coeurjolly, J.-F. Cuevas, F., Waagepetersen, R. (2020).**

Regularized estimation for highly multivariate log Gaussian Cox processes.

*Statistics and Computing* 30, 649-662.



**Crudu, F., Osorio, F. (2020).**

Bilinear form test statistics for extremum estimation.

*Economics Letters* 187, 108885.



**Emery, X., Alegría, A. (2020).**

A spectral algorithm to simulate nonstationary random fields on spheres and multifractal star-shaped random sets.

*Stochastic Environmental Research and Risk Assessment* 34, 2301-2311.



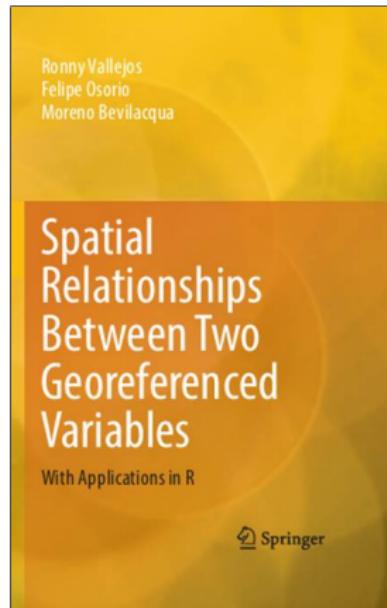
**Vallejos, R., Pérez, J., Ellison, A., Richardson, A. (2020).**

A spatial concordance correlation coefficient with an application to image analysis.

*Spatial Statistics* 40, 100405.



# Asociación espacial entre dos procesos estocásticos (libro Springer)



- ▶ Ronny Vallejos, Felipe Osorio (USM) y Moreno Bevilacqua (UAI).
  - ▶ Asociación entre dos procesos espaciales:
    - procedimientos de test de hipótesis.
    - coeficientes de asociación/codispersión.
    - asociación entre imágenes.
  - ▶ Paquetes en R: [SpatialPack](#) y [GeoModels](#).
-  **Vallejos, R., Osorio, F., Bevilacqua, M. (2020).**  
*Spatial Relationships Between Two Georeferenced Variables: With Applications in R.*  
Springer, Cham.



## Comentarios/dudas?

