

Modelado analítico y basado en datos de histéresis pulmonar

Joaquín Stella¹, Carolina A. Evangelista¹, Diego A. Riva¹, Paul F. Puleston¹

¹GECEP, Instituto LEICI (CONICET-UNLP), Facultad de Ingeniería, UNLP

contacto: joaquin.stella@alu.ing.unlp.edu.ar

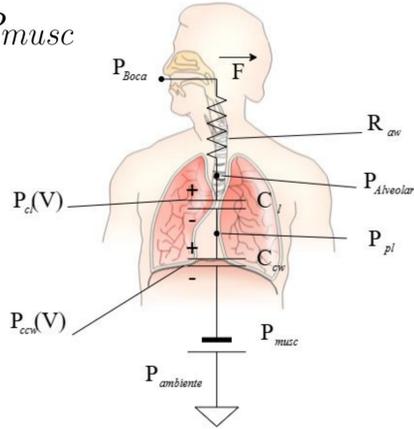
Introducción

En la relación entre la presión en los pulmones y el volumen de aire en el sistema respiratorio humano se da un fenómeno conocido como **histéresis pulmonar**, que puede apreciarse en las **gráficas de presión-volumen (P-V)** como la diferencia de recorrido de la curva durante la inspiración y la espiración. Dado que la curva de histéresis se ve acentuada por enfermedades respiratorias, se modeló esa histéresis ajustando un **modelo general analítico (modelo Vaiana-Rosati)** a los datos de pacientes de SARS-COVID19, y un **modelo de redes neuronales recurrentes (RNN)** a distintos grupos de pacientes.

Para estudiar estas relaciones se puede hacer uso de un modelo circuital, descrito por la **ecuación de movimiento del sistema respiratorio**:

$$P_B = P_{cl}(V) + P_{ccw}(V) + FR_{aw} - P_{musc}$$

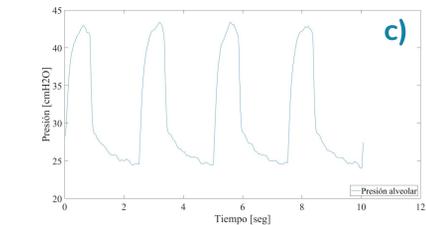
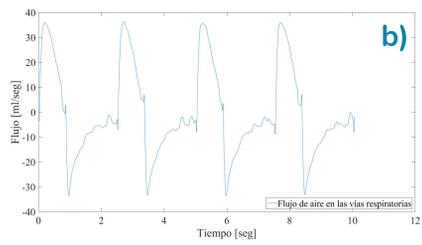
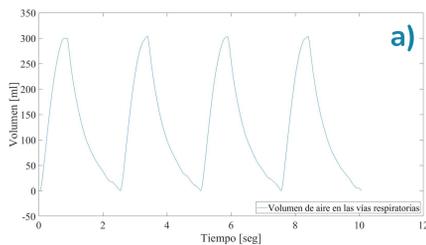
- V : volumen de aire en el sistema
- P_B : la presión en la boca
- P_{cl} : la presión en los pulmones
- P_{ccw} : la presión en la caja torácica
- F : flujo en las vías respiratorias
- R_{aw} : la resistencia en las vías aéreas.
- P_{musc} : la presión muscular



La presión en los pulmones (presión alveolar, P_A) para un paciente anestesiado se puede definir como:

$$P_A = P_B(V) - FR_{aw}$$

Modelo equivalente eléctrico del sistema respiratorio.



Señales de volumen (a), flujo (b) y presión alveolar (c) de un paciente de SARS-COVID19 en 4 ciclos respiratorios.

Parte I: Modelo Vaiana-Rosati

El **modelo de histéresis Vaiana-Rosati** fue desarrollado para representar comportamientos histéreticos observados en distintos materiales en análisis de estructuras.

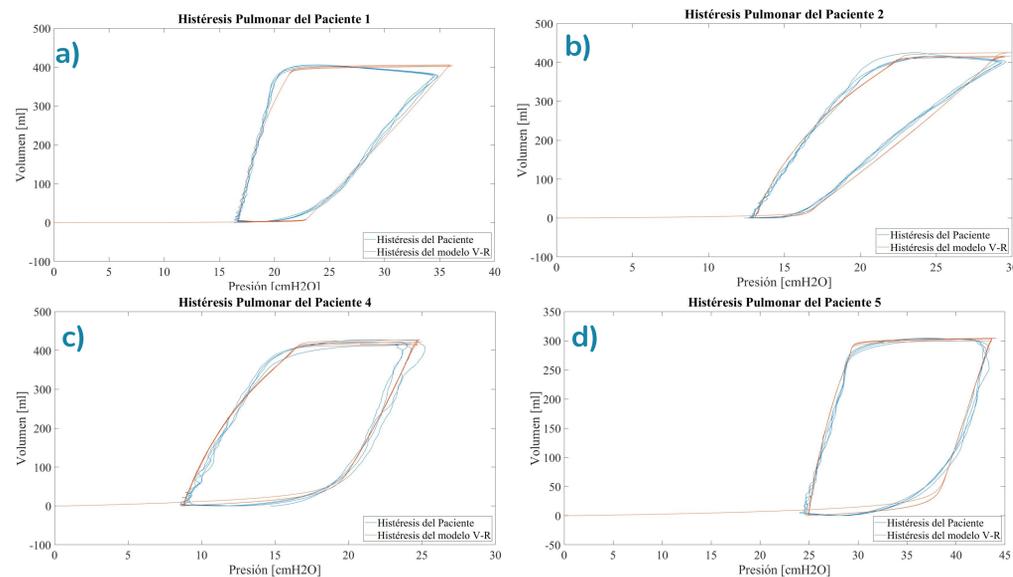
Cuando $\dot{u} > 0$:

$$f(u, u_j^+) = \begin{cases} c^+(u, u_j^+) & \text{when } u < u_j^+ \\ c_u(u) & \text{when } u > u_j^+ \end{cases} \quad (a)$$

Cuando $\dot{u} < 0$:

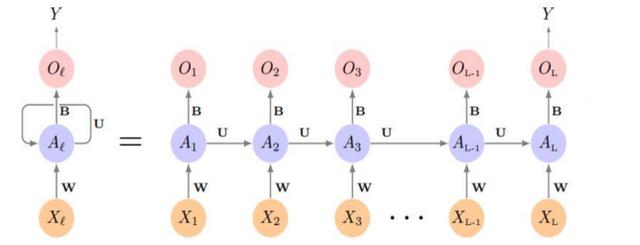
$$f(u, u_j^-) = \begin{cases} c^-(u, u_j^-) & \text{when } u > u_j^- \\ c_l(u) & \text{when } u < u_j^- \end{cases} \quad (a)$$

- El modelo dispone de **16 parámetros ajustables**
- Se modeló un grupo de pacientes de SARS-COVID19, y se ajustó manualmente, modificando solamente **8 de los parámetros**.



Gráficas P-V de los datos de pacientes (azul) y el ajuste del modelo (naranja) para los pacientes 1 (a), 2 (b), 4 (c) y 5 (d).

Parte II: Modelado con Redes Neuronales Recurrentes



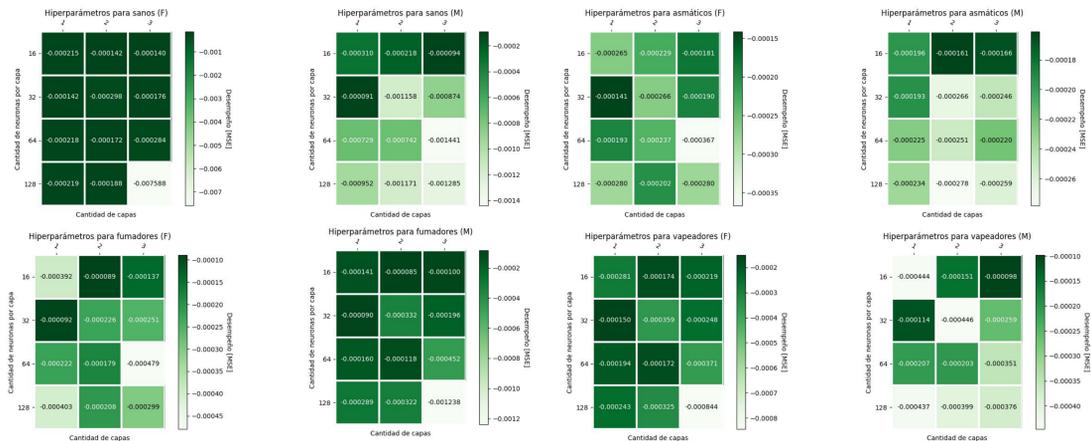
Respuesta de una neurona recurrente simple

Salida de la capa oculta (K neuronas)

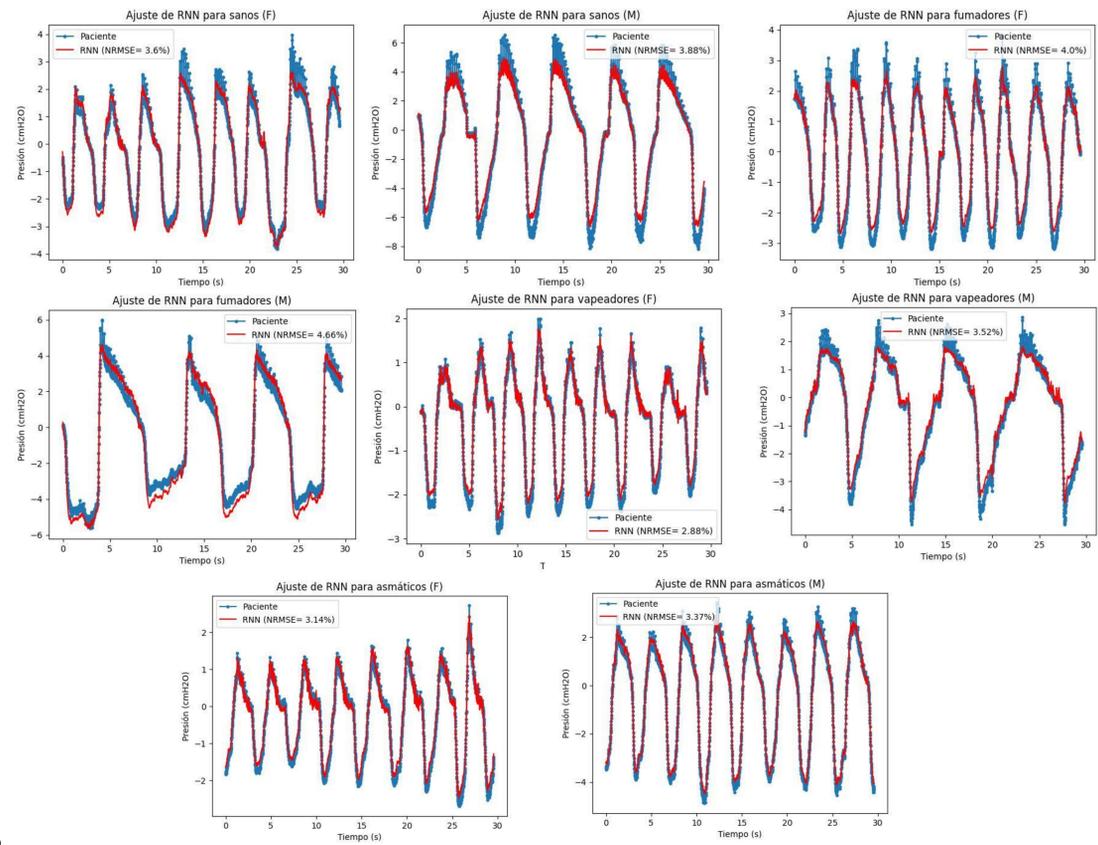
$$A_{tk} = g\left(w_{k0} + \sum_{j=1}^p w_{kj} X_{tj} + \sum_{s=1}^K u_{ks} A_{t-1,s}\right) \quad O_t = \beta_0 + \sum_{k=1}^K \beta_k A_{tk}$$

Neurona recurrente A_t (con parámetros W , U y B), que recibe una entrada X_t y arroja una salida O_t

- Se dispuso de los datos de presión en la boca, volumen y flujo de aire de 80 personas, pertenecientes a cuatro grupos: **sanos**, **fumadores**, **asmáticos** y **vapeadores**, con **10 hombres** y **10 mujeres** en cada uno. Se los modeló separándolos por estado de salud y por sexo.
- Se utilizaron cinco pacientes para buscar sus **hiper-parámetros**, cuatro para **entrenar el modelo** y uno para validar el desempeño de la configuración elegida.



Mapas de calor para la identificación de hiper-parámetros por cantidad de capas (horizontal) y cantidad de neuronas por capa (vertical). Más oscuro \rightarrow menor error (MSE)



Gráficas de señal de presión en la boca para los distintos grupos de pacientes, y su respectivo ajuste con el modelo de redes neuronales recurrentes.

Conclusiones

- \rightarrow Por medio de ambos enfoques, se obtuvieron modelos lo suficientemente realistas como para generar **"pacientes" simulados con distintas características**. Estos pacientes simulados se emplearán para probar nuevas técnicas de ventilación mecánica.
- \rightarrow Se planea desarrollar un **modelo híbrido de histéresis pulmonar**, que combine la flexibilidad y adaptabilidad de los modelos basados en datos (como las redes neuronales) con la interpretabilidad de los modelos paramétricos.