

## Estimación de parámetros basada en aprendizaje profundo para modelado de histéresis pulmonar

J. Stella<sup>1</sup>[0009-0004-4482-1027], C.A. Evangelista<sup>1</sup>[0000-0002-8214-8230],  
D.A. Riva<sup>1</sup>[0000-0002-2580-8837], and P.F. Puleston<sup>1</sup>[0000-0002-7129-1760]

<sup>1</sup>GECEP, Instituto LEICI (UNLP-CONICET), Facultad de Ingeniería, Universidad Nacional de La Plata, Argentina.

joaquin.stella@alu.ing.unlp.edu.ar, cae@ing.unlp.edu.ar,  
diego.riva@ing.unlp.edu.ar, puleston@ing.unlp.edu.ar

**Resumen** La histéresis respiratoria, diferencia de recorrido en la curva presión-volumen entre inspiración y espiración en cada ciclo respiratorio, es un fenómeno que se acentúa ante ciertas enfermedades. Para poder estudiar éstas y analizar estrategias de control ventilatorio, es de interés modelar este aspecto de la fisiología respiratoria. En este trabajo se explora un modelo analítico general de histéresis, surgido en la literatura para representar la relación entre fuerzas aplicadas y correspondientes desplazamientos en diversas estructuras y materiales. Se obtuvo una expresión del modelo que puede corresponderse con la salida de una red neuronal de arquitectura perceptrón multicapa. Luego, usando datos de pacientes reales, se ajustaron los parámetros del modelo recurriendo a una metodología de estimación de parámetros basada en aprendizaje profundo, logrando preliminarmente errores menores a 8% e hiperparámetros de entrenamiento para obtener mejores ajustes. Esta metodología de estimación de parámetros representa un aporte significativo al modelado de histéresis respiratoria y podría aplicarse a otros campos.

**Keywords:** Histéresis respiratoria, Ventilación mecánica, Modelo Vaiana Rosati, Perceptrón Multi-Capa (MLP)

## Deep learning-based parameter estimation for pulmonary hysteresis modeling

**Abstract.** Respiratory hysteresis, the difference in the pressure-volume curve between inspiration and expiration in each respiratory cycle, is a phenomenon that becomes significant in certain diseases. In order to study such effect and analyze ventilatory control strategies, it is useful to model this aspect of respiratory physiology. This work explores the use of a general analytical hysteresis model, which has emerged in the literature to represent the relationship between applied forces and corresponding displacements in various structures and materials. A model expression was obtained that can be matched to the output of a multi-layer perceptron neural network. Then, using data from real patients, the

model parameters were adjusted using a deep learning-based parameter estimation method, with errors less than 8% as well as training hyperparameters to obtain better fits. This parameter estimation method represents a significant contribution to the modeling of respiratory hysteresis and could be applied to other fields.

**Keywords:** Respiratory hysteresis, Mechanical ventilation, Vaiana Rosati model, Multi-Layer Perceptron (MLP)

## 1 Introducción

En el campo de la fisiología respiratoria, una de las gráficas más importantes para realizar diagnósticos sobre un paciente son las llamadas gráficas P-V (presión-volumen), que muestran el volumen de aire ingresado en las vías respiratorias en función de la presión en los pulmones. Esta gráfica permite visualizar un fenómeno conocido como histéresis respiratoria, que ocurre debido a las características físicas de los pulmones y su variación durante el ciclo respiratorio (Bates, 2009). Si bien este fenómeno también ocurre en personas sanas, en los pacientes que padecen distintas enfermedades respiratorias este efecto se puede acentuar considerablemente. Por eso, si se desea modelar el sistema respiratorio de pacientes de patologías respiratorias es de interés capturar la histéresis pulmonar, y calcular los parámetros que la identifican.

Con este propósito, en este trabajo se explora el uso de un modelo general de histéresis para representar la relación entre el volumen y la presión pulmonar de los pacientes, y luego su ajuste por medio de una red neuronal con arquitectura Multi-Layer Perceptron (MLP), diseñada a partir del mismo modelo.

## 2 Metodología

Con el fin de estudiar la relación entre algunas de las señales vitales que participan del ciclo respiratorio, como volumen y flujo de aire y la presión en los distintos tramos del sistema respiratorio, se utiliza un modelo circuital equivalente cuya expresión es la ecuación de movimiento del sistema respiratorio:

$$P_B = P_l(V) + P_{ccw}(V) + FR_{aw} - P_{musc} \quad (1)$$

donde  $V$  es el volumen de aire en el sistema,  $F$  el flujo en las vías respiratorias,  $R_{aw}$  la resistencia en las vías aéreas y  $P_B$ ,  $P_l$ ,  $P_{ccw}$  y  $P_{musc}$  las presiones en la boca, pulmones, caja torácica y la presión muscular, respectivamente. La presión alveolar,  $P_A$ , que presenta el efecto de histéresis, puede expresarse como la suma  $P_A(V) = P_l(V) + P_{ccw}(V) - P_{musc}$ , por lo que se tiene que

$$P_A(V) = P_B - FR_{aw}. \quad (2)$$

Dado que  $P_B$  y  $F$  son las variables usualmente medidas, preliminarmente se calculará la presión alveolar a partir de (2) y un valor típico de  $R_{aw}$ .

En la bibliografía (Flynn, 2016), la histéresis pulmonar se han abordado por medio de distintos modelos, teniendo en cuenta las características propias del fenómeno fisiológico, como la asimetría entre los distintos caminos de la curva durante la espiración y la inspiración. Si se busca disponer de parámetros con un sentido geométrico y, por lo tanto, más interpretables, resulta de interés el modelo general de histéresis de Vaiana y Rosati (Vaiana y Rosati, 2023). Se trata de un modelo desarrollado para realizar análisis estructural, describiendo la histéresis existente entre la fuerza aplicada sobre una estructura con respecto al desplazamiento resultante. En su formulación algebraica, el modelo está descrito como una función a trozos, cuya expresión depende del signo de la derivada de la entrada  $u$ . Cuando éste es positivo, la curva se expresa como  $F^+(u, u_j^+)$  en (3), donde  $c^+$  es la *curva de carga*, y  $c_u$  el recorrido del límite superior de la curva.

$$F^+(u, u_j^+) = \begin{cases} c^+(u, u_j^+) & , u < u_j^+ \\ c_u(u) & , u > u_j^+ \end{cases} ; F^-(u, u_j^-) = \begin{cases} c^-(u, u_j^-) & , u < u_j^- \\ c_l(u) & , u > u_j^- \end{cases} \quad (3)$$

La variable interna  $u_j^+$  se corresponde con la abscisa del punto de intersección de  $c^+$  y  $c_u$ . Cuando la derivada de  $u$  tiene signo negativo, se tiene  $F^-(u, u_j^-)$  en (3), donde  $c^-$  es la *curva de descarga*,  $c_l$  el recorrido del límite inferior de la curva, y la variable interna  $u_j^-$  la abscisa del punto de intersección de  $c^-$  y  $c_l$ .  $c^-$ ,  $c^+$ ,  $c_u$  y  $c_l$  son funciones no lineales del volumen y dependen de un conjunto de 16 parámetros ajustables. La expresión analítica de  $c^+$  y  $c_u$  dado un punto inicial genérico  $(u_p, f_p)$  es (4) y (5), respectivamente, siendo  $\delta_k^+$  un parámetro interno utilizado para calcular  $u_j^+$ .

$$c^+(u, u_p, f_p) = f_e^+(u) + k_b^+ u + f_0^+ - \frac{1}{\alpha^+} \cdot \left\{ \left[ \alpha^+ \left( f_e^+(u_p) + k_b^+ u_p + f_0^+ + \frac{\delta_k^+}{\alpha^+} - f_p \right) \right] e^{-\alpha^+(u-u_p)} - \delta_k^+ \right\} \quad (4)$$

$$c_u(u, u_p, f_p) = f_e^+(u) + k_b^+ u + f_0^+ - (f_e^+(u_p) + k_b^+ u_p + f_0^+) e^{-\alpha^+(u-u_p)} \quad (5)$$

$$f_e^+(u) = \beta_1^+ e^{\beta_2^+ u} - \beta_1^+ + \frac{4\gamma_1^+}{1 + e^{-\gamma_2^+(u-\gamma_3^+)}} - 2\gamma_1^+ \quad (6)$$

Considerando que la curva atraviesa el punto  $(0, 0)$ , asignando  $\delta_k^+ = 0$  y  $\gamma_3^+ = 0$ , se logra simplificar en una única expresión la curva de subida  $F^+$  ( $\dot{u} > 0$ ):

$$f^+(u) = \beta_1^+ (e^{\beta_2^+ u} - 1) + \gamma_1^+ \left( \frac{4}{1 + e^{-\gamma_2^+ u}} - 2 \right) + k_b^+ u + f_0^+ (1 - e^{-\alpha^+ u}) \quad (7)$$

y análogamente, en una expresión única  $f^-(u)$  para la de bajada  $F^-$ .

Para llevar a cabo la estimación de parámetros del modelo, se hizo uso de una red

neuronal *feedforward* con arquitectura Multi-Layer Perceptron (MLP) (Goodfellow et al., 2016). La red neuronal propuesta recibe como entrada la señal de volumen durante la inspiración ( $V^+$ ), y la espiración ( $V^-$ ), y agregando un factor de escalado  $G_s$ , obtiene como salida la presión  $P_B$ . Su estructura se corresponde con la expresión del modelo Vaiana-Rosati simplificado (Fig. 1), tal que:

$$\widehat{P}_B = G_s(f_{net}^+(V^+) + f_{net}^-(V^-)) \quad (8)$$

$$f_{net}^+(V^+) = \beta_1^+ \sigma_1(\beta_2^+ V^+) + \gamma_1^+ \sigma_2(\gamma_2^+ V^+) + f_0^+ \sigma_3(\alpha^+ V^+) + k_b^+ V^+ \quad (9)$$

$$f_{net}^-(V^-) = \beta_1^- \sigma_1(\beta_2^- V^-) + \gamma_1^- \sigma_2(\gamma_2^- V^-) + f_0^- \sigma_3(\alpha^- V^-) + k_b^- V^- \quad (10)$$

siendo  $\sigma_1$ ,  $\sigma_2$  y  $\sigma_3$  funciones de activación que derivan de (7).

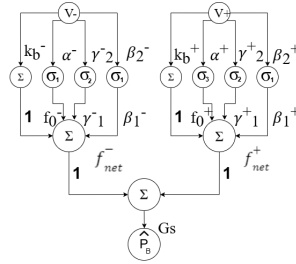


Figura 1: Estructura de la red neuronal propuesta para la estimación.

### 3 Resultados

Para entrenar la red neuronal, se utilizaron datos de pacientes reales de COVID-19, en particular, 4 ciclos respiratorios por cada uno. 3 ciclos se usaron para el entrenamiento, y el cuarto para probar el desempeño. Las señales de flujo fueron procesadas con un filtro de media móvil con una ventana de 10 muestras; además, se normalizaron por medio de la técnica MinMax antes de ser ingresados. Se utilizó una función de pérdida MSE, y el algoritmo de descenso de gradiente Adam, con un *learning rate* de 0.001. Tras realizar una comprobación con distintas combinaciones de hiperparámetros, se decidió emplear batches de 64 muestras y 400 epochs durante el entrenamiento. Para calcular  $P_A$ , se utilizó  $R_{aw} = 0,002 \text{ cmH}_2\text{O.s/ml}$ , un valor estimado experimentalmente. En el Cuadro 1 se muestran los valores de ajuste obtenidos para cada paciente, y en la Fig. 2, as histeresis ajustadas de los pacientes N°3 y N°4.

### 4 Conclusiones y Trabajo A Futuro

El modelo Vaiana-Rosati presenta características que lo hacen adecuado para el modelado de histeresis respiratoria, pero el ajuste de sus parámetros puede suponer una dificultad dado su cantidad y diversidad de efectos. Eso ha motivado la




Figura 2: Curva P-V del paciente N°3 (izq.) y N°4 (der.), y el ajuste del modelo.

Cuadro 1: Error NRMSE de los ajustes para los datos de cada paciente.

Paciente (N°)	1	2	3	4	5	6	7
Error (NRMSE)	0,062	0,050	0,033	0,042	0,059	0,060	0,056

aparición de modelos híbridos, que buscan integrar las ventajas de los abordajes paramétricos y de los modelos basados en datos (Wang et al., 2023). El modelo ajustado es estático, pero se buscará la arquitectura de la red para estimar los parámetros de su versión dinámica. Además, esta línea de investigación pretende seguir explorando el uso de modelos de aprendizaje profundo para estimar otros parámetros propios de la histéresis respiratoria, como el de  $R_{aw}$ , alcanzando así un modelado más completo del sistema respiratorio humano.

## 5 Agradecimientos

Los autores agradecen el financiamiento y apoyo de la Facultad de Ingeniería - Universidad Nacional de La Plata, CONICET, CICpBA y ANCyT.

## Referencias

- Bates, J. H. T. (2009). *Lung Mechanics: An Inverse Modeling Approach*. Cambridge University Press.
- Flynn, D. (2016). A survey of hysteresis models of mammalian lungs. *Sem. Mat. Univ. Politec. Torino*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Vaiana, N., & Rosati, L. (2023). Analytical and differential reformulations of the Vaiana-Rosati model for complex rate-independent mechanical hysteresis phenomena. *Mechanical Systems and Signal Processing*, 199, 110448.
- Wang, T., Noori, M., Altabey, W. A., Wu, Z., Ghiasi, R., Kuok, S.-C., Silik, A., Farhan, N. S., Sarhosis, V., & Farsangi, E. N. (2023). From model-driven to data-driven: A review of hysteresis modeling in structural and mechanical systems. *Mechanical Systems and Signal Processing*, 204, 110785.