

III Jornada de Innovación en Cuidados Continuos

MADRID, 4 DE DICIEMBRE 2025




LA INTELIGENCIA ARTIFICIAL EN LA PREDICCIÓN DEL RIESGO DE TROMBOSIS Y/O SANGRADO.

Dr. Ignacio García Escobar

Oncología Médica

Hospital Universitario de Toledo

Diciembre 2025



Medicine and the Computer — The Promise and Problems of Change

William B. Schwartz, M.D.

Los rápidos avances en las ciencias de la información, [...], prometen provocar cambios básicos en la estructura de la práctica médica. La ciencia de la computación probablemente ejercerá sus principales efectos al aumentar y, en algunos casos, reemplazar en gran medida las funciones intelectuales del médico[...]. Solo a través de la consideración de tales costos potenciales será posible introducir la nueva tecnología de manera efectiva y aceptable.



INDICE

- • **Contextualización**
- • Definición y aspectos teóricos
- • Justificación de necesidad: aplicación en medicina
- • Aplicación en trombosis

¿Revolución industrial?

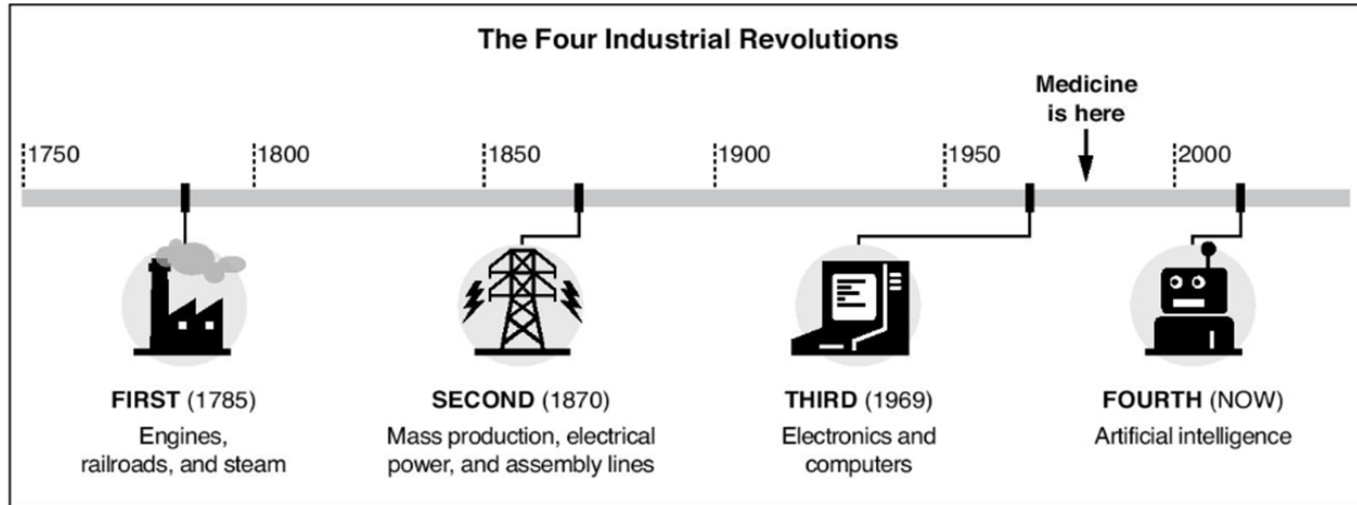
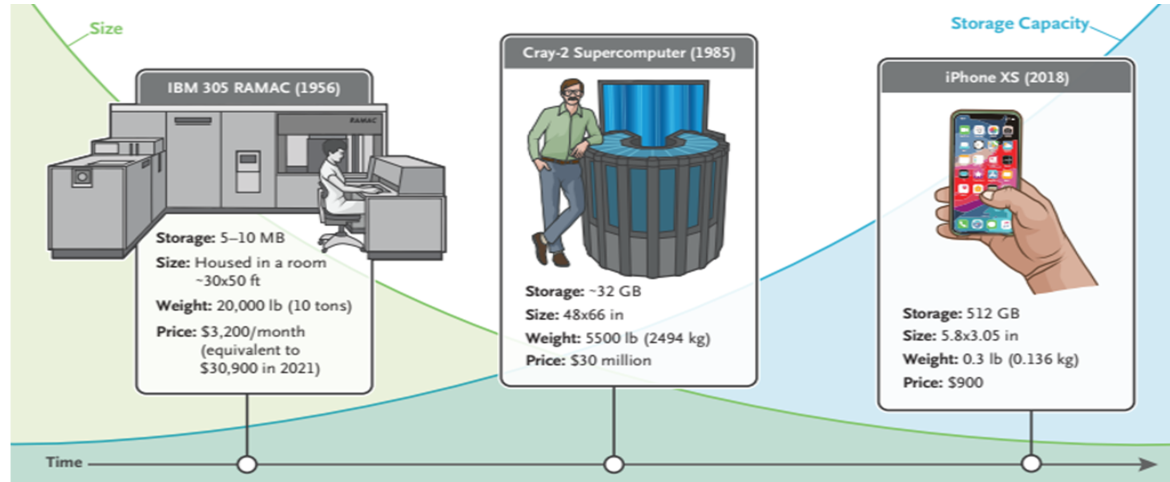


FIGURE 1.4: The four Industrial Revolutions. Source: Adapted from A. Murray, "CEOs: The Revolution Is Coming," *Fortune* (2016): <http://fortune.com/2016/03/08/davos-new-industrial-revolution>.

INTELIGENCIA ARTIFICIAL



INTELIGENCIA ARTIFICIAL

Son parte de nuestra vida diaria y pueden ayudarnos a realizar tareas definidas.

Haug CJ, et al. N Engl J Med 2023; 388:1201-8.

ASISTENTES VIRTUALES BASADOS EN IA



alexa



siri



openAI



microsoft

CHATBOTS

INDICE

- • Contextualización
- • **Definición y aspectos teóricos**
- • Justificación de necesidad: aplicación en medicina
- • Aplicación en trombosis

BASES DE LA IA

- Los modelos de la IA se basan en la combinación de algoritmos y datos.
- **Algoritmos:**

Instrucciones o reglas que le indican a la máquina como *procesar la información* y realizar ciertas tareas.

Los algoritmos *varían según el tipo de problema*: reconocimiento de imágenes, traducción de idiomas o diagnósticos médicos

- **Datos:** pueden ser imágenes, texto, sonidos o cualquier información relevante.
Cantidad y de calidad.

Los modelos de IA se basan en algoritmos que guían el procesamiento de la información en grandes conjuntos de datos que permiten a la máquina aprender y realizar tareas específicas

TÉRMINOS Y DEFINICIONES

➔ INTELIGENCIA ARTIFICIAL

Programa informático que permite que una máquina imite o reproduzca funciones cognitivas como el aprendizaje y la toma de decisiones que normalmente se asocian con los seres humanos.

➔ ¿QUÉ ENGLOBA LA IA?

Big data

Capacidad de procesar cantidades masivas de datos estructurados y no estructurados que pueden cambiar constantemente.



Aprendizaje

Capacidad de aprender en base a patrones históricos, aportes de expertos y circuitos de retroalimentación.

Razonamiento

Capacidad de razonar (deductiva o inductiva) y de sacar inferencias basadas en la situación. Conciencia del sistema impulsado por el contexto.

Resolución de problemas

Capaz de analizar y resolver problemas complejos en un dominio de propósito general y especial.

ENFOQUES Y TECNICAS DE LA IA

NATURAL LANGUAGE PROCESSING (NLP)

rama de la inteligencia artificial que se ocupa de la interacción entre los ordenadores y el lenguaje humano natural, es decir, el lenguaje que hablamos y escribimos cotidianamente.

MACHINE LEARNING (ML)

rama de la inteligencia artificial que implica el desarrollo de programas informáticos que pueden analizar datos, observar patrones en esos datos y aprender de ellos sin ser programados explícitamente para hacerlo.

REINFORCEMENT LEARNING (RL)

Este enfoque implica que el algoritmo aprenda a través de la interacción con un entorno, recibiendo retroalimentación en forma de recompensas o castigos según su comportamiento.



DEEP LEARNING (DL):

Subconjunto del aprendizaje automático que utiliza redes neuronales artificiales con múltiples capas (redes neuronales profundas) para aprender de grandes cantidades de datos. Este enfoque se ha vuelto muy popular en campos como el reconocimiento de imágenes y el procesamiento del lenguaje natural.

INDICE

- • Contextualización
- • Definición y aspectos teóricos
- • **Justificación de necesidad: aplicación en medicina**
- • Aplicación en trombosis

APLICACIONES EN MEDICINA



Clinical-Trial Performance
Decision support in trial design
Patient identification, recruitment, and retainment
Outcome and side-effect monitoring



Retrieval of Medical Information
Use of multiple information sources about a patient to make a diagnosis
Internet search engines
EMR decision support



Operational Organization
Operating-room scheduling
Billing and collections
Patient follow-up



APLICACIONES EN MEDICINA

PROS | CONS



- Mejora la capacidad de diagnóstico y, por ende, la eficacia de los tratamientos.
 - Ayuda en la toma de decisiones clínicas.
 - Mejora la experiencia formativa de los profesionales
 - Optimiza y reduce los tiempos de investigación.
 - Establece nuevas vías de estudio, inviables para la lógica humana.
 - Mejora la prevención y detección temprana de enfermedades.
 - Aumenta la calidad de la atención médica y, en consecuencia, la calidad de vida de los pacientes.
- Privacidad y seguridad de los datos
 - Sesgo algorítmico
 - Ausencia de explicabilidad
 - Falta de validación clínica
 - Responsabilidad y transparencia
 - Consentimiento informado
 - Equidad en el acceso y la atención

IA en Oncología: desde prevención al tratamiento

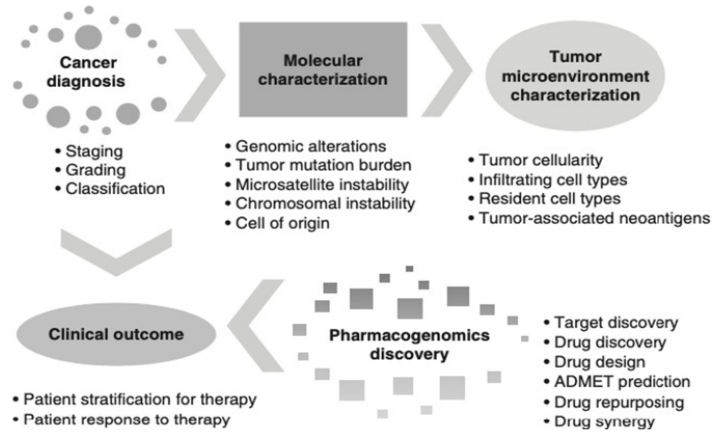
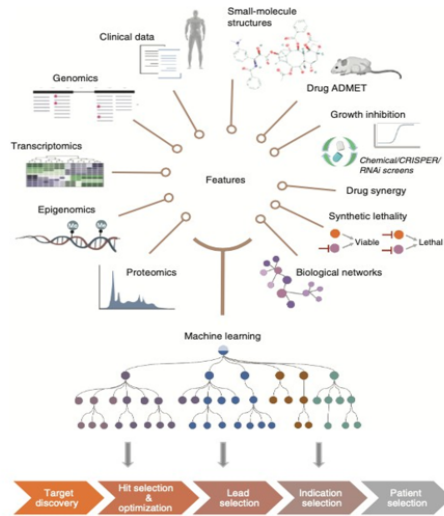


Figure 4. Integrating datasets from multiple diverse sources, ranging from sequencing to structure to screening datasets, can increase the relevant feature space for AI models that enable end-to-end drug discovery.

INDICE

- • Contextualización
- • Definición y aspectos teóricos
- • Justificación de necesidad: aplicación en medicina
- • **Aplicación en trombosis**

¿Y EN TROMBOSIS ASOCIADA A CÁNCER?

En los pacientes con cáncer, el TEV es el resultado de una serie de factores de riesgo que pueden dividirse en factores de riesgo relacionados con el paciente, con el tumor, con el tratamiento y con los biomarcadores¹

Factores de riesgo relacionados con el paciente

- Edad avanzada³
- Sexo femenino³
- Raza²
- Antecedentes de TEV³
- Comorbilidades del paciente³
- Inmovilización prolongada³
- Factores trombofílicos heredados³

Factores de riesgo relacionados con el cáncer

- Localización²: neoplasias hematológicas, pulmón, páncreas, estómago, cerebro, riñón
- Estadio²: estadio avanzado y periodo inicial tras el diagnóstico
- Histología del cáncer²
- Tiempo después del diagnóstico²
- Genómica²

Factores de riesgo relacionados con el tratamiento del cáncer

- Cirugía y hospitalización²
- Quimioterapia² y terapia hormonal¹
- Terapia antiangiogénica²
- Agentes estimulantes de la eritropoyesis²

Biomarcadores

- Recuento de plaquetas (>350000 por μL)³
- Recuento de leucocitos (>11000 por μL)³
- Dímero D¹
- Células tumorales sobre la expresión del factor tisular²
- Factor tisular circulante³
- P-selectina soluble¹
- Proteína C reactiva¹

Alta complejidad en la capacidad de predicción de eventos

- Tres capas de información clínica:
 - Paciente
 - Tumor
 - Tratamiento antitumoral
- Dos capas de información molecular (genética)
 - Paciente
 - Tumor
- Posibilidad de solapamiento (factores de confusión)

Aplicaciones de la IA en trombosis y cáncer

- ▶ IA: herramienta valiosa para la detección, prevención y tratamiento de la trombosis
- ▶ Modelos de IA para detectar **patrones con un alto impacto** en el diagnóstico temprano de la trombosis analizando especialmente pruebas de imagen: detectar signos tempranos de trombosis
- ▶ Analizar historial médico mediante técnicas de reconocimiento del lenguaje natural para **identificar factores de riesgo**.
- ▶ **Elaboración de modelos predictivos** y mejora del tratamiento

Aplicaciones en diagnóstico temprano


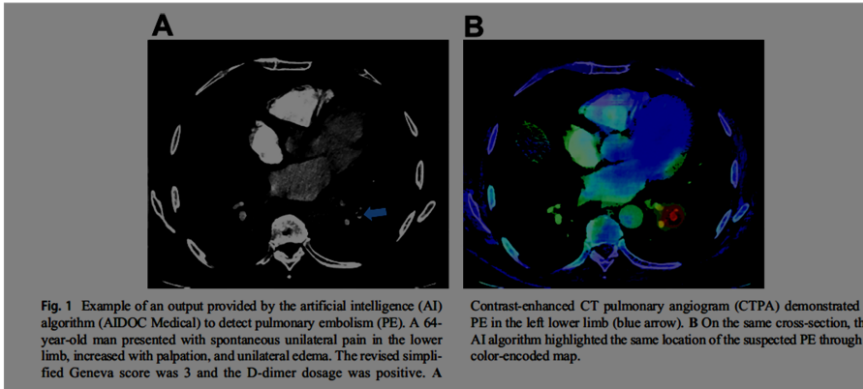
European Radiology (2022) 32:5831–5842
<https://doi.org/10.1007/s00330-022-08645-2>

IMAGING INFORMATICS AND ARTIFICIAL INTELLIGENCE



How artificial intelligence improves radiological interpretation in suspected pulmonary embolism

Alexandre Ben Cheikh^{1,2} · Guillaume Gorincour^{1,3} · Hubert Nivet^{1,4,5} · Julien May¹ · Mylene Seux¹ · Paul Calame^{6,7} · Vivien Thomson^{1,2} · Eric Delabrousse^{6,7} · Amandine Crombé^{1,8,9}



Cheik, AB, et al. Eur Radiol (2022) 32:5831–5842

Aplicaciones en diagnóstico temprano

- Se incluyeron en cohorte B **1202 pacientes** (edad media: 66.2 años).
- La **prevalencia** de EP fue del **15.8%** (190/1202).
- El algoritmo de IA detectó 219 EP sospechosos, de los cuáles 176 fueron reales, **19 verdaderos no detectados por radiólogos**.
- Las mayor sensibilidad y VPN con IA (92.6% versus 90% Y 98.6% versus 98.1%, respectivamente).
- Las mayor especificidad y VPP con radiólogos (99.1% versus 95.8% y 95% versus 80.4%, respectivamente).
- **Los radiólogos utilizaron el algoritmo de IA para mejorar el diagnóstico** (55/79 [69.6%]).

Riesgo de recurrencia: modelo de Ottawa



Table 2. Ottawa Score for Recurrent VTE Risk in Cancer-Associated Thrombosis

Variable	Regression Coefficient	Points
Female	0.59	1
Lung cancer	0.94	1
Breast cancer	-0.76	-1
TNM* stage I	-1.74	-2
Previous VTE	0.40	1
Clinical probability		
Low (≤ 0)	...	-3 to 0
High (≥ 1)	...	1 to 3

VTE indicates venous thromboembolism.

*TNM (tumor-nodes-metastasis staging system) for solid tumors only.

Louzada et al. *Circulation* 2012

Validation of the Ottawa prognostic score for the prediction of recurrent venous thromboembolism in patients with cancer-associated thrombosis

P. L. DEN EXTER, J. KOOLMAN and M. V. HUIJSMAN
Department of Thrombosis and Hemostasis, Leiden University Medical Center, Leiden, the Netherlands

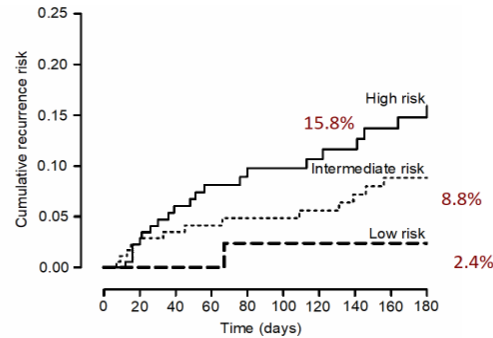


Table 1 Patient characteristics

Age (years), mean \pm SD	60 \pm 15
Male sex, n (%)	222 (52.9)
BMI, mean \pm SD	25 \pm 5
Inpatient, n (%)	127 (30.3)
Previous VTE, n (%)	39 (9.3)
Primary tumor site, n (%)	
Lung	64 (15.3)
Breast	33 (7.9)
Colorectal	35 (8.4)
Other GI site	43 (10.3)
Gynecologic	24 (5.7)
Other solid	155 (37.0)
Hematologic	65 (15.5)
Metastatic disease*, n (%)	252 (71.2)

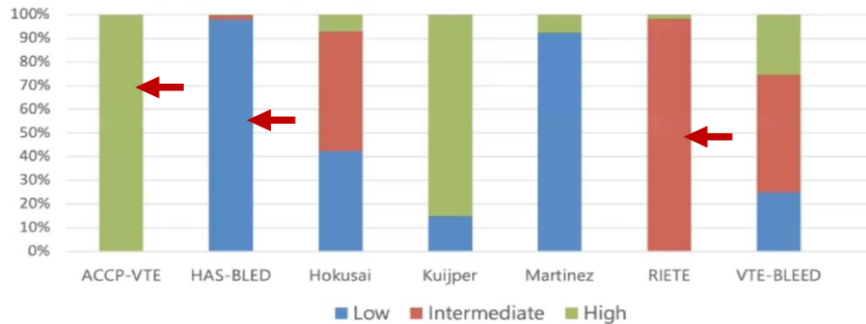
BMI, body mass index; GI, gastrointestinal; SD, standard deviation; VTE, venous thromboembolism.
*In case of a solid malignancy.

Den Exter et al. *J Thromb Haemost* 2015

OC12.3: Estimating bleeding risk in patients with cancer-associated thrombosis: external validation of existing risk scores and development of a new risk score (MA de Winter et al.)

Existing risk scores

Hokusai-VTE Cancer patients divided in risk categories based on existing risk scores



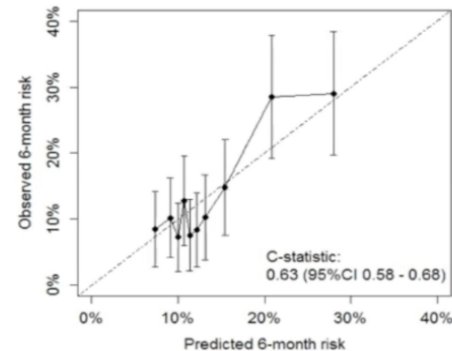
	C-statistic (95% CI)
ACCP-VTE	0.50 (0.50-0.50)
HAS-BLED	0.52 (0.45-0.59)
Hokusai	0.52 (0.44-0.60)
Kuijper et al.	0.51 (0.46-0.56)
Martinez et al.	0.55 (0.49-0.61)
RIETE	0.57 (0.49-0.65)
VTE-BLEED	0.50 (0.50-0.51)

Modelo predictivo de sangrado

OC12.3: Estimating bleeding risk in patients with cancer-associated thrombosis: external validation of existing risk scores and development of a new risk score (MA de Winter et al.)

New prediction model: CAT-BLEED

	sHR (95% CI)
Genitourinary cancer	2.48 (1.14-5.38)
GI cancer * edoxaban treatment ←	2.20 (1.07-4.53)
Anticancer therapies associated with GI toxicity	1.74 (1.03-2.92)
Regionally advanced or metastatic cancer	1.21 (0.82-1.80)
Age >75 years	1.02 (0.98-1.08)
Creatinine clearance (mL/min)	1.00 (0.99-1.00)

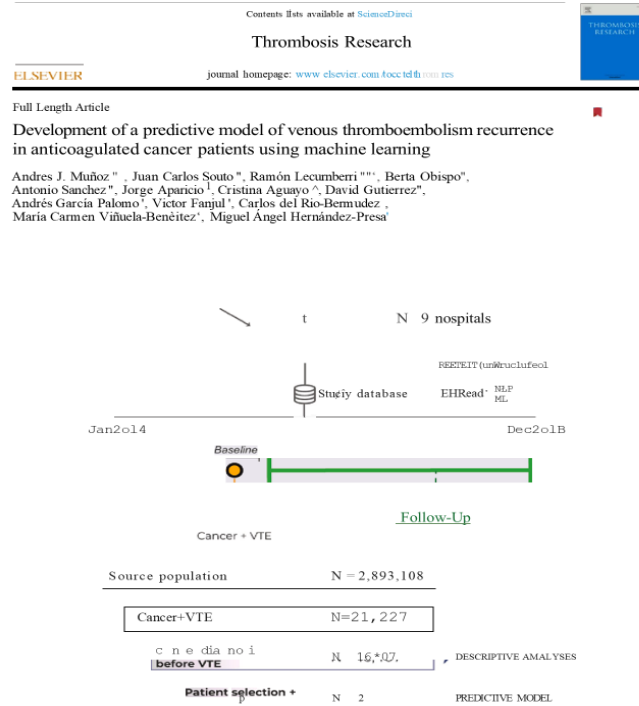


Modelo predictivo de sangrado

- Desarrollado en una **población muy selectiva de pacientes dentro de un EC** fase III que no representan a la población con cancer.
- La **variable relacionada con edoxabán** es equiparable para otros anticoagulantes?
- **Pobre e inespecífica definición de toxicidad GI**
- Pendiente validación externa

Modelo predictivo de sangrado: score B-CAT

Predictor	Eventos de sangrado	Subdistribución HR ajustada (IC del 95 %)	Puntuación
Tipo de cáncer			
Cáncer del tracto gastrointestinal superior	42	1,48 (1,00-2,21)	1
Cáncer de cérvix	11	2,65 (1,33-5,28)	1
Cáncer de próstata	84	1,52 (1,03-2,24)	1
Tumores del sistema nervioso central	21	2,36 (1,38-4,02)	1
Cáncer de riñón	20	1,49 (0,87-2,56)	1
Cáncer de vejiga	42	1,85 (1,25-2,74)	1
Melanoma	13	1,74 (0,94-3,22)	1
Estadio			
Metástasis	279	1,65 (1,36-1,99)	1
Cirugía menor tras ETV asociada a cáncer activo	95	1,59 (1,21-2,11)	1
Trauma menor	54	2,00 (1,46-2,75)	1
Sangrado antes de ETV asociada a cáncer activo			
SM alguna vez antes	24	2,00 (1,23-3,25)	1
SNMCR <2 años	187	1,77 (1,43-2,18)	1
SNMCR-NH tras ETV asociada a cáncer activo	20	1,86 (1,15-3,02)	1
Comorbilidades			
Accidente cerebrovascular	73	2,44 (1,79-3,33)	1
Enfermedad gastroduodenal	36	2,19 (1,47-3,27)	1
Anemia	149	2,31 (1,85-2,88)	1
Trastorno de la coagulación	9	2,15 (1,09-4,24)	1



Características del estudio

- Estudio **multicéntrico, observacional y retrospectivo**
- **9 hospitales** del sistema nacional de salud entre el 1 de Enero 2014 y el 31 diciembre de 2018
- Basado en datos de la historia clínica electrónica del paciente
- Análisis transversal de las variables incluidas
- Se utilizó la tecnología **EH Read** que utilizó **NLP, ML** y técnicas de aprendizaje profundo para la extracción de datos y su migración a la base de datos

ENFOQUES Y TECNICAS DE LA IA

NATURAL LANGUAGE PROCESSING (NLP)

rama de la inteligencia artificial que se ocupa de la interacción entre los ordenadores y el lenguaje humano natural, es decir, el lenguaje que hablamos y escribimos cotidianamente.

MACHINE LEARNING (ML)

rama de la inteligencia artificial que implica el desarrollo de programas informáticos que pueden analizar datos, observar patrones en esos datos y aprender de ellos sin ser programados explícitamente para hacerlo.

REINFORCEMENT LEARNING (RL)

Este enfoque implica que el algoritmo aprenda a través de la interacción con un entorno, recibiendo retroalimentación en forma de recompensas o castigos según su comportamiento.

DEEP LEARNING (DL):

Subconjunto del aprendizaje automático que utiliza redes neuronales artificiales con múltiples capas (redes neuronales profundas) para aprender de grandes cantidades de datos. Este enfoque se ha vuelto muy popular en campos como el reconocimiento de imágenes y el procesamiento del lenguaje natural.

Características

Table 1
Demographics and comorbidities at the time of VTE diagnosis.

	N = 16,407
Demographics	
Gender, n (%)	16,407 (100)
Male	8925 (54.4)
Female	7482 (45.6)
Age, years	
Mean (SD)	68.44 (14.71)
Median (Q1, Q3)	70 (59, 80)
Comorbidities, n (%)	
Hypertension	9583 (58.4)
Neurological diseases ^a	8544 (52.1)
Dyslipidemia	6647 (40.5)
Psychiatric disorders	5234 (31.9)
Diabetes mellitus	4713 (28.7)
Heart failure	3880 (23.6)
Kidney failure	3787 (23.1)
Atrial fibrillation	2946 (18)
Cerebrovascular accident	2862 (17.4)
COPD	2661 (16.2)
Varicose veins	2565 (15.6)
Arterial thromboembolic events	1769 (10.8)
Peripheral artery disease	1087 (6.6)
Acute myocardial infarction	1063 (6.5)
Inherited thrombophilia	941 (5.7)
Asthma	738 (4.5)
Chronic hepatopathy	572 (3.5)
Transient ischemic attack	460 (2.8)

COPD: Chronic obstructive pulmonary disease.

^a Neurological diseases include peripheral neurotoxicity, neuropathy, and neurological pain.

Table 2
Clinical characteristics at the time of VTE diagnosis.

	N = 16,407
VTE-related characteristics	
VTE subtype, n (%)	
Deep vein thrombosis	11,026 (67.2)
Pulmonary embolism	4360 (26.6)
Synchronous pulmonary and deep vein thrombosis	759 (4.6)
Visceral vein thrombosis	1207 (7.4)
Splenic thrombosis	587 (3.6)
Portal thrombosis	587 (3.6)
Other type of VTE	235 (1.4)
Family history of VTE	416 (2.5)
History of major bleeding ^a	1928 (11.8)
History of CRNMB ^a	1711 (10.4)
Cancer-related characteristics	
Primary cancer location n (%)	
Colorectal cancer	1705 (10.4)
Lung cancer	1471 (9)
Bladder cancer	1210 (7.4)
Breast cancer	1135 (6.9)
Hematological cancer	1101 (6.7)
Prostate cancer	993 (6.1)
Pancreatic cancer	815 (5)
Endometrial cancer	625 (3.8)
Cervix cancer	419 (2.6)
Gastric cancer	339 (2.1)
Esophageal cancer	303 (1.8)
Brain cancer	285 (1.7)
Kidney cancer	229 (1.4)
Bile duct cancer	180 (1.1)
Ovarian cancer	139 (0.8)
Thyroid cancer	121 (0.7)
Vulvar cancer	8 (0)
Vaginal cancer	2 (0)
Other cancer locations	5782 (35.2)
Other characteristics n (%)	
Complete remission	809 (4.9)
Metastasis	7822 (47.7)
Adenocarcinoma	5574 (34)
Tumors with mucosal involvement	2973 (18.1)

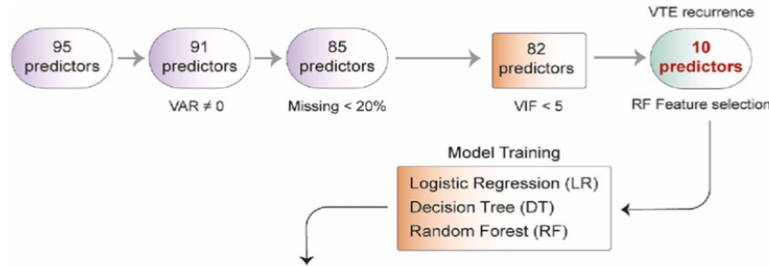
CRNMB: Clinically relevant non-major bleeding; MB: Major bleeding; SD: Standard deviation; VTE: venous thromboembolism.






^a MB and CRNMB events calculated based on ISTH criteria.

Características del estudio

- Fueron considerados 10 predictores de recurrencia de ETV: características demográficas, historia familiar, características del tumor y del evento trombótico, parámetros de laboratorio
- Fueron de alto riesgo: historia familiar, EP, mtx
- Fueron de bajo riesgo: plaquetas, DTV y edad
- La variable tipo de tumor: tenía asociación pero no se incluía en el modelo
- La localización y patrón de recurrencia varió según el tipo de tumor

Resultados



Variable		LR		DT	RF	
		Coeff.	SE	Imp.	Imp.	
	Demographics	Age	-0.003	0.004	<0.001	0.057
	Family history	VTE	1.721	0.282	0.205	0.063
	VTE characteristics	Pulmonary embolism	0.603	0.142	0.278	0.181
		Deep vein thrombosis	-0.444	0.135	0.112	0.177
	Oncological characteristics	Metastasis	0.588	0.106	0.176	0.153
		Adenocarcinoma	0.490	0.109	<0.001	0.084
	Laboratory parameters	Hemoglobin	<0.001	0.023	0.081	0.076
		Platelet count	>-0.001	0.001	0.022	0.072
		Serum creatinine	0.006	0.018	0.063	0.075
		Leukocyte count	-0.007	0.006	0.063	0.063

e18744 Publication Only

Predicting major bleeding events in anticoagulated cancer patients with venous thromboembolism using real-world data and machine learning.

Methods: Observational, retrospective, and multicenter study based on the secondary analysis of unstructured clinical data in electronic health records (EHRs). Using the EH-Read technology, based on Natural Language Processing (NLP) and machine learning (ML), data were collected from EHRs from 9 Spanish hospitals between 2014 and 2018.

A total of 94 patient characteristics were

explored Among a source population of

2,893,208 patients,

21,227 anticoagulant-treated patients with VTE and active cancer were identified from EHRs.

The following predictors of MB were identified: hemoglobin levels, presence of metastasis, patient's age, platelet count, leukocyte count, and serum creatinine levels.

Clinical and Translational Oncology (2025) 27:1816–1825
<https://doi.org/10.1007/s12094-024-03586-2>

RESEARCH ARTICLE



Prediction model for major bleeding in anticoagulated patients with cancer-associated venous thromboembolism using machine learning and natural language processing

Andrés J. Muñoz Martín¹ · Ramón Lecumberri^{2,3} · Juan Carlos Souto⁴ · Berta Obispo⁵ · Antonio Sanchez⁶ · Jorge Aparicio⁷ · Cristina Aguayo⁸ · David Gutierrez⁹ · Andrés García Palomo¹⁰ · Diego Benavent¹¹ · Miren Taberna¹¹ · María Carmen Viñuela-Benítez¹² · Daniel Arumi¹³ · Miguel Ángel Hernández-Presa¹³

Clinical and Translational Oncology (2025) 27:4031–4039
<https://doi.org/10.1007/s12094-025-03890-5>

RESEARCH ARTICLE



External validation of a prediction model for bleeding events in anticoagulated cancer patients with venous thromboembolism (PredictAI)

María Carmen Viñuela-Benítez¹ · Claudia Iglesias Pérez² · Laura Ortega Morán³ · Ignacio García Escobar⁴ · Diego Cacho Lavín⁵ · Rut Porta i Balanya⁶ · Silvia García Adrián⁷ · Marta Carmona Campos⁸ · Gretel Benítez López⁹ · José Antonio Santiago Crespo¹⁰ · Miriam Lobo de Mena¹¹ · Javier Pérez Altozano¹² · Enrique Gallardo Díaz¹³ · Julia Tejerina Peces¹⁴ · Pilar Ochoa Rivas¹⁵ · María José Ortiz Morales¹⁶ · Victoria Eugenia Castellón Rubio¹⁷ · Carmen Díez Pedroche¹⁸ · María Rosales Sueiro¹⁹ · Felipe Gonçalves²⁰ · Manuel Sánchez-Cánovas²¹ · Miguel Ángel Ruiz²² · José Muñoz-Langa²³ · Pedro Pérez Segura¹⁴ · Eva Martínez de Castro⁵ · Alberto Carmona-Bayonas²¹ · Paula Jiménez-Fonseca² · Andrés Jesús Muñoz Martín³

Received: 11 January 2025 / Accepted: 25 February 2025 / Published online: 26 April 2025
© The Author(s) 2025

scientific reports



OPEN

Prediction of pulmonary embolism by an explainable machine learning approach in the real world

Qiao Zhou^{1,2,3}, Ruichen Huang^{1,3}, Xingyu Xiong^{2✉}, Zongan Liang^{2✉} & Wei Zhang^{1✉}



TYPE Original Research
PUBLISHED 06 October 2025
DOI 10.3389/fdata.2025.1605258



OPEN ACCESS

EDITED BY
Rodrigo Assar,
University of Chile, Chile

REVIEWED BY
Ibrahim F. Rehan,
Menoufia University, Egypt
Eric Munger,
United States Department of Veterans Affairs,
United States

*CORRESPONDENCE
Biao Song
✉ songbiao_511@163.com

Predicting deep vein thrombosis using machine learning and blood routine analysis

Jie Su^{1,2†}, Yuechao Tang^{3†}, Yanan Wang⁴, Chao Chen⁴ and Biao Song^{4,5*}

¹Medical Neurobiology Laboratory, Inner Mongolia Medical University, Hohhot, China, ²Inner Mongolia Health Digital Society, Hohhot, China, ³Baoding Second Central Hospital, Baoding, China, ⁴Medical Intelligent Diagnostics Big Data Research Institute, Hohhot, China, ⁵Inner Mongolia University of Finance and Economics, Hohhot, China

30/11/25, 10:30

El Hospital público Infanta Leonor lidera un estudio que utiliza IA para detectar cáncer oculto - Revista Pharma Market

Domingo, 30 de
Enero de 2025

PHARMA MARKET

Política sanitaria Tecnología Industria Farmacia Hospitales Legislación I+D Nombramientos Opinión Entrevistas RSC
| Concienciados | Entre Bastidores |

ES NOTICIA

I-D

16 de abril, 2025

El Hospital público Infanta Leonor lidera un estudio que utiliza IA para detectar cáncer oculto



Conclusiones

- ▶ La toma de decisiones médicas basadas en IA es un tema cada vez más relevante que además colabora en la implementación de la medicina personalizada y de precisión.
- ▶ Necesidad de scores que evalúen el riesgo ETEV y hemorragia en el paciente con CAT a lo largo de todo el proceso.
- ▶ IA nos ofrece una oportunidad para procesar datos de la historia clínica digitalizada de los pacientes y establecer algoritmos para realizar tareas y tomar decisiones.
- ▶ Importantes cuestiones éticas, legales, de privacidad y confidencialidad.

