



Perspectivas futuras de la IA en la investigación y tratamiento del cáncer

José A. Seoane

*Grupo de Biología Computacional del Cáncer
Vall d'Hebron Instituto de Oncología. Barcelona*



“Deberíamos parar de formar radiólogos ahora mismo. Es totalmente obvio que en los próximos 5 años el deep learning lo hará mejor que los radiólogos”

Geoff Hinton, 2016



“Deberíamos parar de formar radiólogos ahora mismo. Es totalmente obvio que en los próximos 5 años el deep learning lo hará mejor que los radiólogos”

Geoff Hinton, 2016

“La transición es ligeramente más lenta de lo que yo esperaba, pero estoy bastante seguro que la IA interpretará muchos tipos de imágenes médicas mejor que la mayoría de los radiólogos para 2026”

Geoff Hinton, 2022

The Cancer Researcher

Online magazine for the cancer research community

EACR
European Association
for Cancer Research



“La inteligencia artificial no está tomando el control, solo está cambiando cosas”



“La inteligencia artificial no está tomando el control, solo está cambiando cosas”

Colaboración entre los clínicos e investigadores traslacionales para el desarrollo, validación e implantación de las herramientas de IA


¿Cuánto tiempo hace que usamos la IA en la práctica clínica?

- **PAM50**
Estratificación molecular de cáncer de mama
Usado para predecir el riesgo de recaídas y uso de quimioterapia



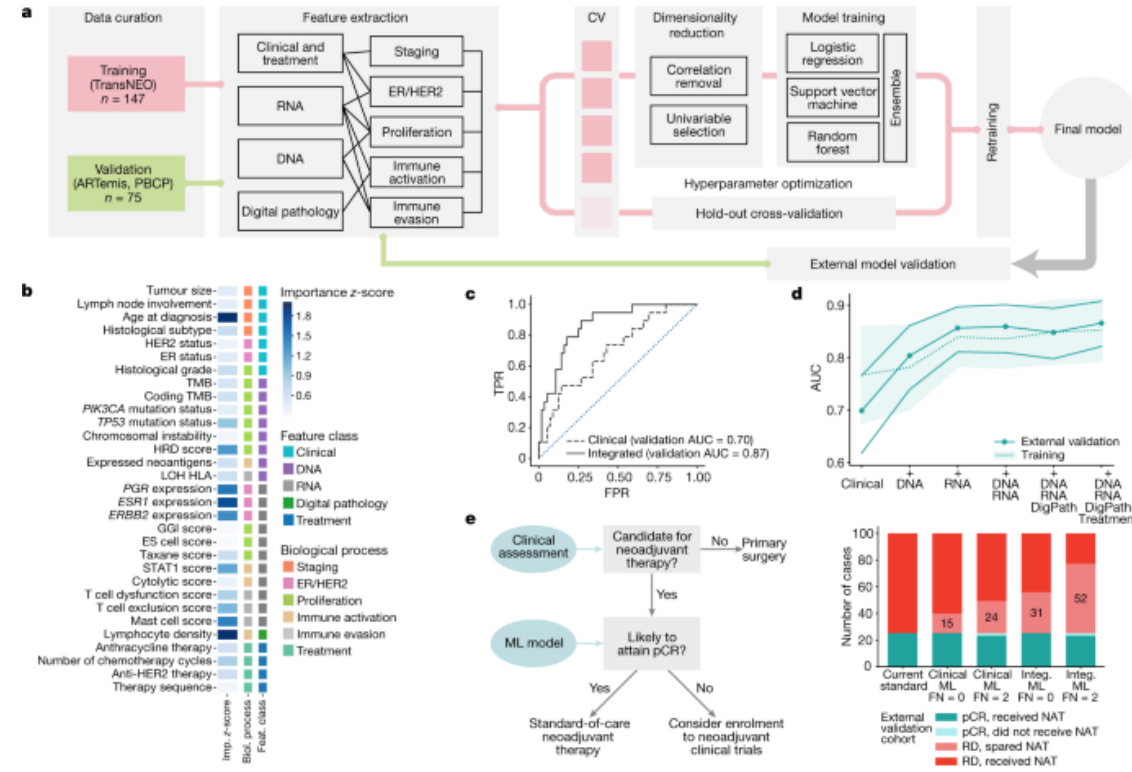
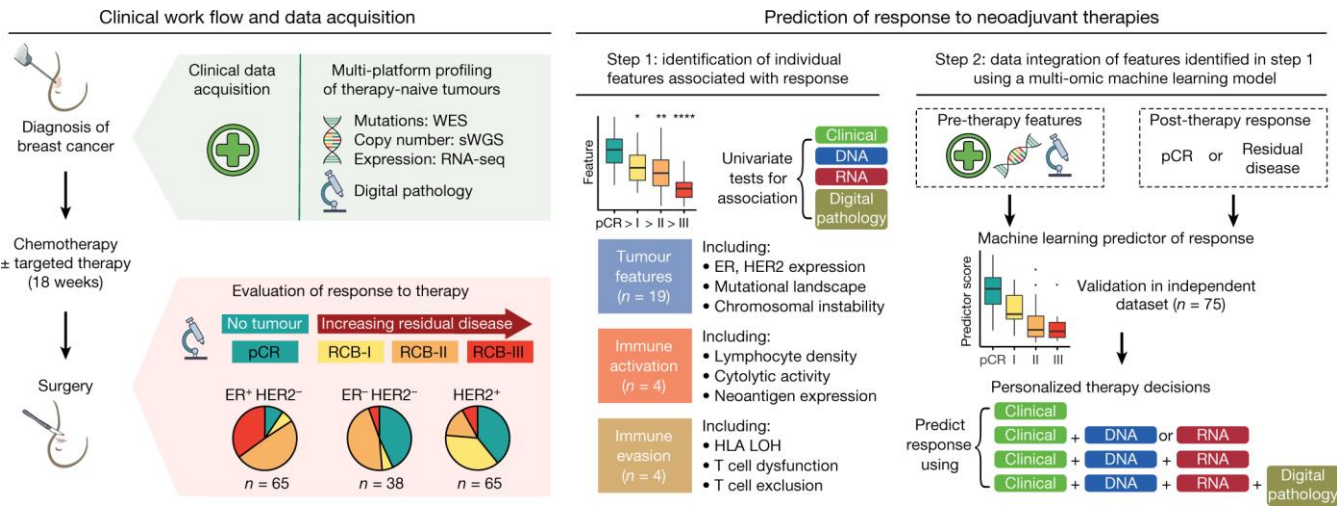
¿Cuanto tiempo hace que usamos la IA en la práctica clínica?

- **PAM50**
Estratificación molecular de cáncer de mama
Usado para predecir el riesgo de recaídas y uso de quimioterapia
- **Clasificación cáncer gástrico**
CIN, GS, EBV y MSI
TCGA, Nature 2014
ESMO Gastric cancer clinical guidelines Lordick 2022



Tratamiento basado en predicción

Predicción de respuesta a quimioterapia en cáncer de mama



Diagnóstico utilizando histopatología

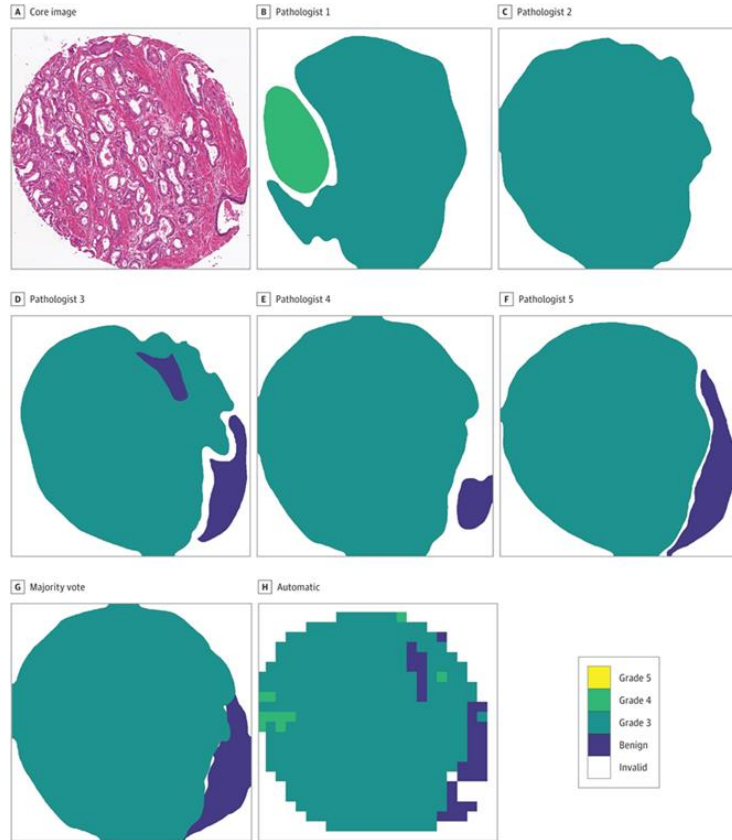


Table 2. Results of the Cross-Validation Experiments

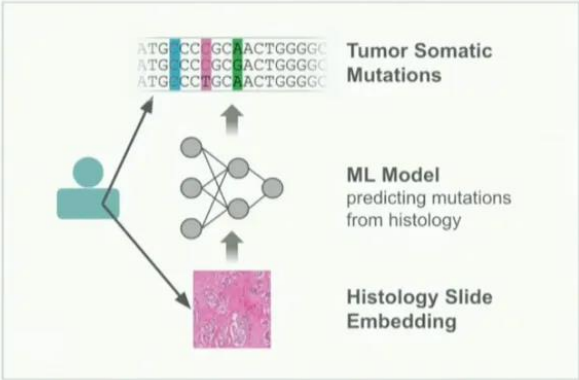
Cross-Validation Method	Classification	Accuracy, Mean (SD), %	Sensitivity, Mean (SD), %	Specificity, Mean (SD), %
20-Fold leave-patients-out	Benign vs cancer	85.8 (4.3)	86.3 (4.1)	85.5 (7.2)
	Low-grade vs high-grade	81.2 (3.7)	82.4 (5.0)	82.0 (8.1)
20-Fold leave-cores-out	Benign vs cancer	86.7 (3.7)	87.2 (4.0)	87.7 (5.5)
	Low-grade vs high-grade	83.4 (4.5)	86.2 (6.4)	84.2 (4.9)
20-Fold leave-patches-out	Benign vs cancer	97.8 (1.2)	98.5 (1.0)	97.5 (1.2)
	Low-grade vs high-grade	92.2 (4.5)	93.8 (5.8)	90.8 (6.0)
2-Fold leave-patches-out	Benign vs cancer	96.8 (0.0)	96.8 (0.0)	97.2 (0.0)
	Low-grade vs high-grade	87.0 (0.0)	84.1 (0.0)	94.1 (0.0)

Nir et al. JAMA Netw Open 2019


Histopatología como predictor de marcadores moleculares

Embeddings Predict Tumor Genetics

We Trained an ML Model to Predict Tumor Genotype from Histology Embedding



Somatic Mutation Detection in Breast Cancer (N=960 cases)



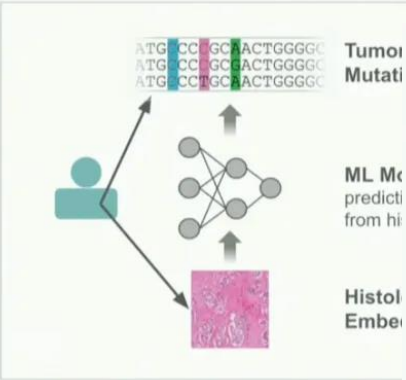
Predictive accuracy on held-out samples is comparable to fully supervised models, underscoring the utility of unsupervised embeddings as a basis for association discovery

Histopatología como predictor de marcadores moleculares

Embeddings Predict Tumor Genetics

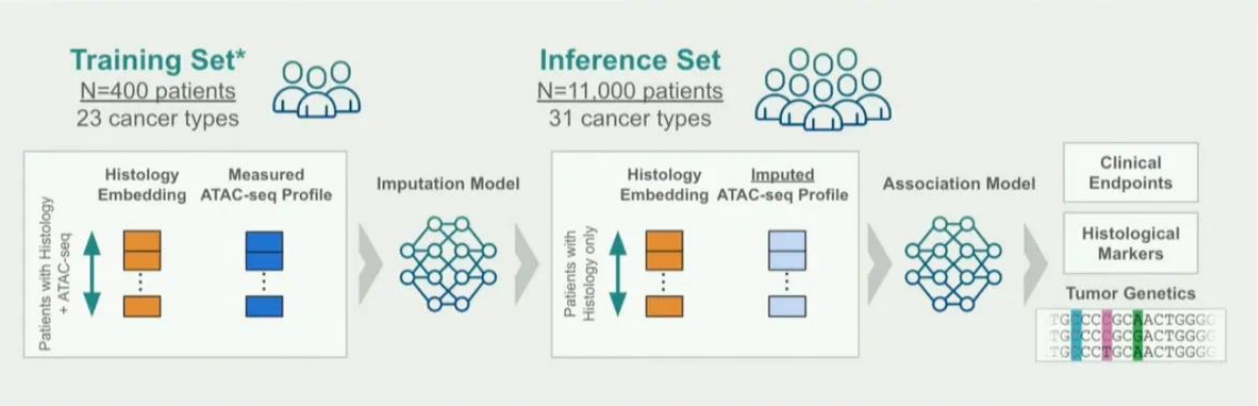
We Trained an ML Model to Predict Tumor Genotype from Histology Embedding

Somatic Mutation Detection in Breast Cancer (N=960 cases)



Imputing Molecular Measurements from Histopath Embeddings

Using ML to predict ATAC-seq signal from histology alone across a large cohort




Predictive accuracy on held-out data underscoring the utility of using histology to predict tumor genetics



Inteligencia artificial para desarrollo de fármacos

- Identificación de nuevas dianas terapéuticas




AlphaFold

Inteligencia artificial para desarrollo de fármacos

- Identificación de nuevas dianas terapéuticas




Alphamissense



Alphafold

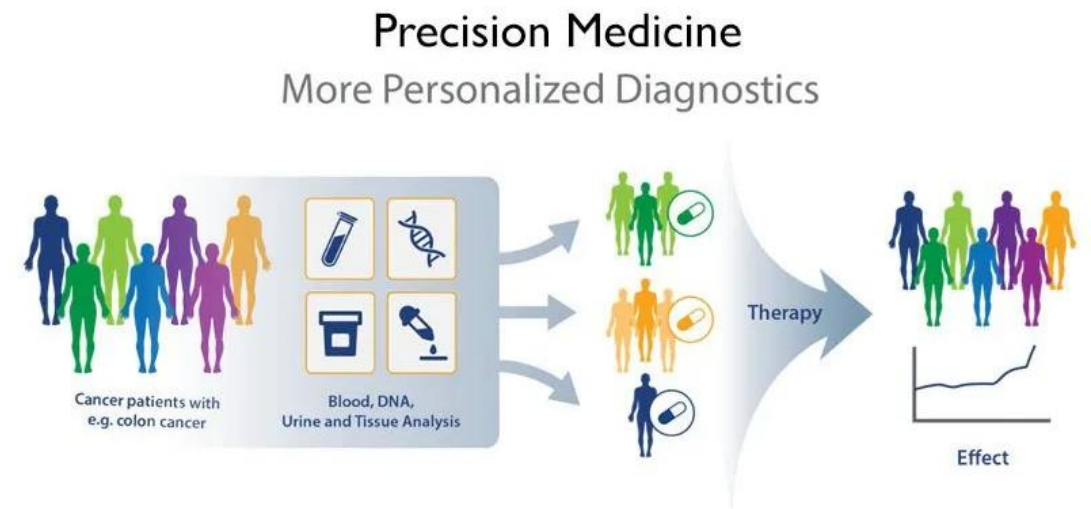
Inteligencia artificial para desarrollo de fármacos

- Identificación de nuevas dianas terapéuticas
- Desarrollo de nuevos fármacos
 - Predecir seguridad de un fármaco
 - Predecir la efectividad de un fármaco
 - Desarrollos automáticos de nuevos fármacos



Inteligencia artificial para desarrollo de fármacos

- Identificación de nuevas dianas terapéuticas
- Desarrollo de nuevos fármacos
 - Predecir seguridad de un fármaco
 - Predecir la efectividad de un fármaco
 - Desarrollos automáticos de nuevos fármacos
- Tratamiento de precisión




Inteligencia artificial para desarrollo de fármacos

- Identificación de nuevas dianas terapéuticas
- Desarrollo de nuevos fármacos
 - Predecir seguridad de un fármaco
 - Predecir la efectividad de un fármaco
 - Desarrollos automáticos de nuevos fármacos
- Tratamiento de precisión
- Predecir el resultado de un clinical trial

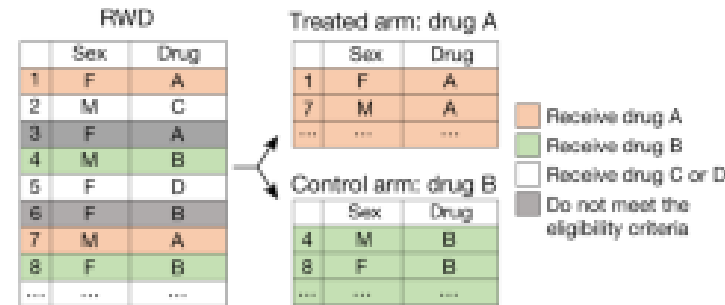
Aplicación de la IA en el diseño de ensayos clínicos

a Trial emulation

(1) Implementation and encoding of eligibility criteria



(2) Generation of treatment groups




(3) Emulate blind assignment

Use IPTW to adjust for confounding factors:


- Demographics: age, gender, race, smoking status, and so on.
- Status: group stage, ECOG, and so on.
- Biomarkers: ALK, PDL1, and so on.
- Other factors

(4) Survival analysis



b Analysis

Change eligibility criteria in silico:



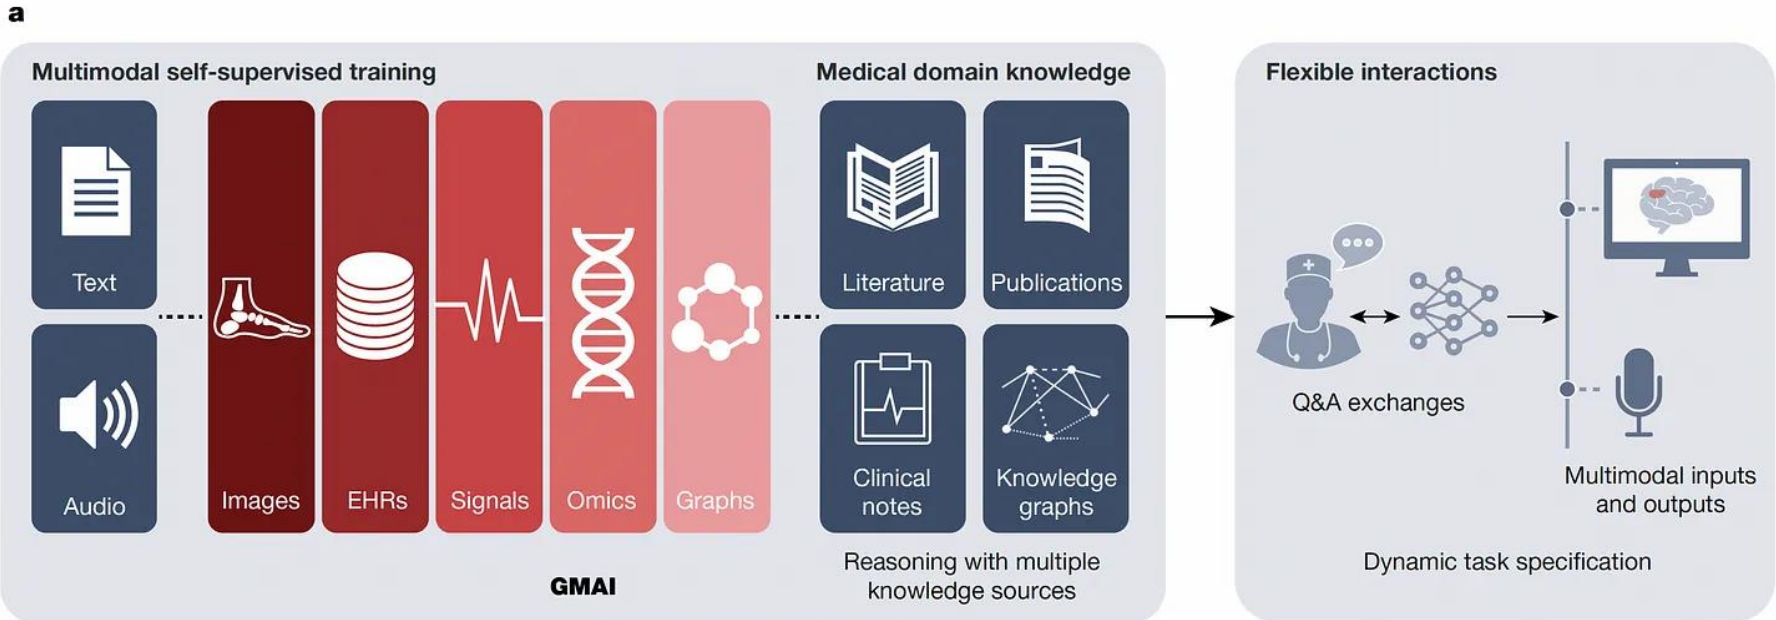
Influence of each rule

Contribution of one rule:
change in the number of patients;
change in HR

Criteria relaxation

The set of rules:
large cohort; low HR


Generative AI como nueva historia clínica



Regulations: Application approval; validation; audits; community-based challenges; analyses of biases, fairness and diversity

De la clínica al laboratorio


- IA para data processing
 - Extraer información estructurada de las historias clínicas
 - Extraer información estructurada de los ensayos clínicos
- IA para identificar candidatos para ensayos preclínicos



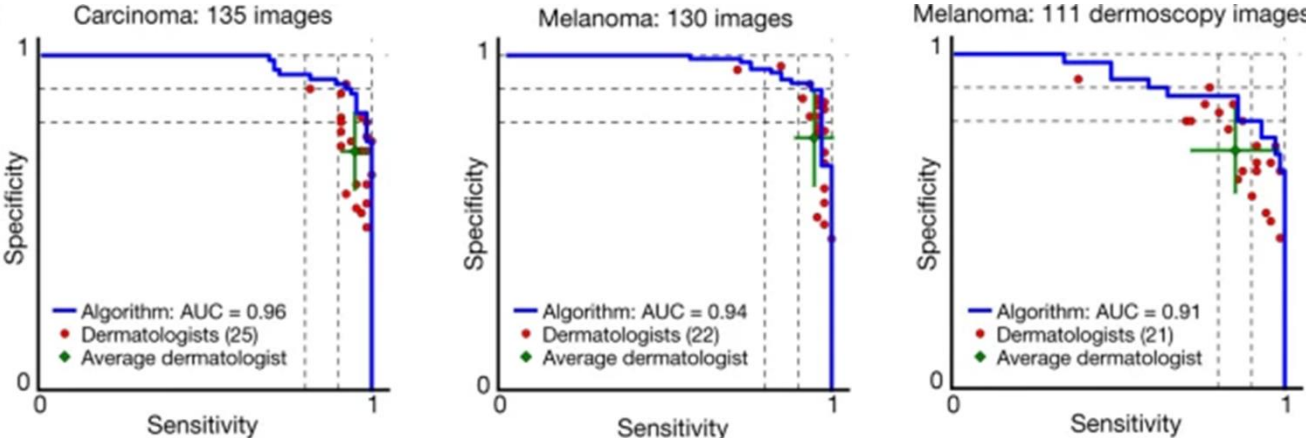
Papel de los sesgos en el uso de IA en la práctica clínica

Ejemplo de diagnóstico de melanomas utilizando fotografías

b



a



nature

Explore content About the journal Publish with us

nature > letters > article

Published: 25 January 2017

Dermatologist-level classification of skin cancer with deep neural networks


Andre Esteva, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau & Sebastian Thrun

Nature 542, 115–118 (2017) | Cite this article

191k Accesses | 5017 Citations | 2949 Altmetric | Metrics

Papel de los sesgos en el uso de IA en la práctica clínica

Ejemplo de diagnóstico de melanomas utilizando fotografías



This article is more than 2 years old

AI skin cancer diagnoses risk being less accurate for dark skin - study

Research finds few image databases available to develop technology contain details on ethnicity or skin type



Most viewed



Elon Musk calls strikes 'insane' as Swedish workers take on Tesla



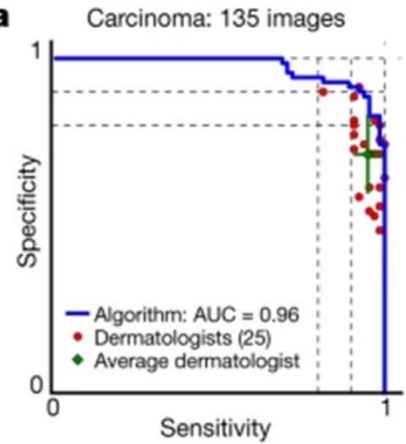
'You can walk around in a shirt': how Norway brought heat pumps in from the cold



Trump called Iowa evangelicals 'so-called Christians' and 'pieces of shit', book says



Live Israel-Hamas war live pause in fighting to begin




IA en oncología

Problemas potenciales

- Sesgos en los datos o modelos
 - Sesgos poblacionales: si los datos no son una muestra real de la población
 - Sesgos técnicos: falta de datos, sobreentrenamiento
- Problemas regulatorios
 - Solo una pequeña porción de los desarrollos llegan a aprobarse por las agencias regulatorias
 - La gran mayoría de las aplicaciones basadas en IA aprobadas por la FDA están relacionadas con la radiología.
- Problemas técnicos
 - Integración con los sistemas hospitalarios y usabilidad
- Explicabilidad
 - Los modelos de IA son normalmente cajas negras, pero las decisiones clínicas deben ser justificadas apropiadamente

Preguntas



Jose A. Seoane

joseaseoane@vhio.net

@seoaneja