


# De texto libre a datos estructurados en cardiología: desarrollo y validación de un clasificador interpretable basado en ontología clínica

Rafael Salguero-Bodes(1), Rocío Tello de Meneses Becerra(2), Jorge Solís Martín(2), Carmen Alonso Casero(3), Lourdes Vicent Alaminos(4) y Fernando Arribas Ynsaurriaga(5) de (1)Servicio de Cardiología. Instituto de Investigación Sanitaria imas12. Hospital Universitario 12 de Octubre. CIBERCV. Facultad de Medicina. Universidad Complutense, Madrid - España, (2)Servicio de Cardiología. Instituto de Investigación Sanitaria imas12. Hospital Universitario 12 de Octubre, Madrid - España, (3)Instituto de Investigación Sanitaria imas12. Hospital Universitario 12 de Octubre, Madrid - España, (4)Servicio de Cardiología. Instituto de Investigación Sanitaria imas12. Hospital Universitario 12 de Octubre. CIBERCV, Madrid - España y (5)Servicio de Cardiología. Instituto de Investigación Sanitaria imas12. Hospital Universitario 12 de Octubre. CIBERCV. Facultad de Medicina. Universidad Complutense, Madrid - España

Introducción: Muchas derivaciones a cardiología se generan con información clínica en texto libre no estructurado, limitando su uso para priorización y gestión clínica. El objetivo fue desarrollar y validar un sistema interpretable capaz de estructurar automáticamente estos textos y evaluar su reproducibilidad y concordancia con evaluadores clínicos.

Métodos: A partir del análisis retrospectivo de 69.801 derivaciones presenciales (2011–2025), se desarrolló una e-ontología clínica y un clasificador determinista basado en reglas léxico-semánticas para identificar 18 categorías clínicas codificadas de ?1 (negación) a 2 (motivo activo relevante), junto con variables derivadas de complejidad. Para la validación, se seleccionaron 30 derivaciones de forma intencional con casos frontera y clínicamente informativos (simples, complejos, multicategoría, con negaciones y no cardiológicos).
Tres evaluadores clínicos independientes clasificaron cada caso según el contenido literal del texto (sin inferencia). Se calcularon porcentaje de acuerdo y ? de Krippendorff (ordinal). Se construyó un gold standard por mayoría (2/3) y se evaluó la concordancia del modelo automático mediante coeficiente kappa.

Resultados: La concordancia interobservador fue elevada (P=0,92; ?=0,80), con consenso completo en el 84% de las observaciones. Las categorías con mayor reproducibilidad incluyeron insuficiencia cardiaca, enfermedad coronaria, dolor torácico, disnea y síncope (?>0,85), mientras que palpitaciones (?=0,52) y “otros” (?=0,47) mostraron menor acuerdo. El modelo automático alcanzó una concordancia elevada frente al gold standard (P=0,96; kappa=0,74), comparable a la variabilidad entre evaluadores humanos. Las discrepancias se concentraron en la jerarquización clínica y en categorías semánticamente ambiguas.

Conclusiones: La estructuración automática de derivaciones mediante un modelo interpretable basado en ontología es factible, reproducible y clínicamente robusta a gran escala.
El sistema muestra un rendimiento comparable al de evaluadores clínicos, permitiendo automatizar el triaje,

mejorar la priorización asistencial y habilitar el uso secundario de datos.

Las discrepancias identificadas delimitan áreas específicas de mejora para su integración en práctica clínica real.

**Categorías incluidas en la ontología**

| ENTIDADES CARDIOVASCULARES MAYORES | ARRITMIAS Y ALTERACIONES DEL RITMO | SÍNTOMAS CARDIOVASCULARES | HALLAZGOS Y CONTEXTO CLÍNICO |
|---|---|---|---|
| Insuficiencia cardiaca | | Dolor torácico | Soplo |
| Enfermedad coronaria | Fibrilación auricular | Disnea | Alteración ECG |
| Valvulopatía | Extrasistolia | Palpitaciones | Factores de riesgo cardiovascular |
| Enfermedad vascular | Bradicardia | Síncope | Revisión programada |
| Enfermedad heredable | | Presíncope / mareo | Otros |