

Original

Rendimiento y optimización de la herramienta *trigger* en la detección de eventos adversos en pacientes adultos hospitalizados

Óscar Guzmán Ruiz^{a,*}, Juan José Pérez Lázaro^b y Pedro Ruiz López^c

^a Servicio de Medicina Interna, Sección de Geriatría, Centre Hospitalier EpiCURA, Baudour, Belgique

^b Escuela Andaluza de Salud Pública, Granada, España

^c Hospital Universitario 12 de Octubre, Madrid, España

INFORMACIÓN DEL ARTÍCULO

Historia del artículo:

Recibido el 7 de septiembre de 2016

Aceptado el 24 de enero de 2017

On-line el xxx

Palabras clave:

Seguridad del paciente

Evento adverso

Error médico

Efecto adverso

RESUMEN

Objetivo: Caracterizar el rendimiento de los *triggers* utilizados en la detección de eventos adversos (EA) de pacientes adultos hospitalizados y definir un panel de *triggers* simplificado suficientemente sensible y específico, para la detección de EA.

Método: Estudio transversal de altas de pacientes de un servicio de medicina interna para la detección de EA mediante revisión sistemática de la historia clínica y la identificación de 41 *triggers* (evento clínico relacionado frecuentemente con EA), determinando si hubo EA según el contexto en que apareció el *trigger*. Una vez identificado el EA, se procedió a la caracterización de los *triggers* que lo detectaron. Se aplicó regresión logística para la selección de los *triggers* con mayor capacidad de detección de EA.

Resultados: Se revisaron 291 historias clínicas y se detectaron 562 *triggers* en 103 pacientes, de los cuales 163 estuvieron implicados en la detección de un EA. Los *triggers* que detectaron más EA fueron «A.1. Úlcera por presión» (9,82%), «B.5. Laxante o enema» (8,59%), «A.8. Agitación» (8,59%), «A.9. Sobresedación» (7,98%), «A.7. Hemorragia» (6,75%) y «B.4. Antipsicótico» (6,75%). Se obtuvo un modelo simplificado de *triggers* que incluyó la variable «Número de fármacos» y los *triggers* «Sobresedación», «Sondaje», «Reingreso en 30 días», «Laxante o enema» y «Cese brusco de la medicación». Este modelo obtuvo una probabilidad del 81% de clasificar correctamente las historias con EA y sin EA ($p < 0,001$; intervalo de confianza del 95%: 0,763-0,871).

Conclusiones: Un número elevado de *triggers* estuvieron asociados a EA. El modelo resumido permite detectar una gran cantidad de EA con un mínimo de elementos.

© 2017 SESPAS. Publicado por Elsevier España, S.L.U. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Performance and optimisation of a trigger tool for the detection of adverse events in hospitalised adult patients

ABSTRACT

Objective: To characterise the performance of the triggers used in the detection of adverse events (AE) of hospitalised adult patients and to define a simplified panel of triggers to facilitate the detection of AE.

Method: Cross-sectional study of charts of patients from a service of internal medicine to detect EA through systematic review of the charts and identification of triggers (clinical event often related to AE), determining if there was AE as the context in which it appeared the trigger. Once the EA was detected, we proceeded to the characterization of the triggers that detected it. Logistic regression was applied to select the triggers with greater AE detection capability.

Results: A total of 291 charts were reviewed, with a total of 562 triggers in 103 patients, of which 163 were involved in detecting an AE. The triggers that detected the most AE were "A.1. Pressure ulcer" (9.82%), "B.5. Laxative or enema" (8.59%), "A.8. Agitation" (8.59%), "A.9. Over-sedation" (7.98%), "A.7. Haemorrhage" (6.75%) and "B.4. Antipsychotic" (6.75%). A simplified model was obtained using logistic regression, and included the variable "Number of drugs" and the triggers "Over-sedation", "Urinary catheterisation", "Readmission in 30 days", "Laxative or enema" and "Abrupt medication stop". This model showed a probability of 81% to correctly classify charts with EA or without EA ($p < 0.001$; 95% confidence interval: 0.763-0.871).

Conclusions: A high number of triggers were associated with AE. The summary model is capable of detecting a large amount of AE, with a minimum of elements.

© 2017 SESPAS. Published by Elsevier España, S.L.U. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Keywords:

Patient safety

Adverse event

Medical error

Adverse effect

* Autor para correspondencia.

Correo electrónico: oguzmanruiz@yahoo.es (Ó. Guzmán Ruiz).

Introducción

Los sistemas sanitarios tienen en consideración la importancia de la existencia de eventos adversos (EA) y utilizan una variedad de estrategias para detectar peligros con el fin de prevenir daños en los pacientes. Según la Organización Mundial de la Salud, los EA son incidentes que causan daño al paciente, y se considera daño cualquier alteración estructural o funcional del organismo o todo efecto perjudicial derivado de ella. Los daños comprenden las enfermedades, las lesiones, los sufrimientos, las discapacidades y la muerte, y pueden ser físicos, sociales o psicológicos¹.

En estudios efectuados en varios países, los EA presentan una frecuencia entre el 3,7% y el 16,6% de las hospitalizaciones²⁻⁶, llegando a un 6,6% los EA que condujeron al fallecimiento del paciente³. Asimismo, el impacto económico es muy elevado. En España, un estudio realizado en el período 2008-2010 determinó que el coste incremental de los EA fue de 88.268.906 €, calculándose un sobrecoste de un 6,7% del total del gasto sanitario⁷.

Existen diversos métodos para la detección de EA, como la revisión de las historias clínicas (utilizado en la mayor parte de los estudios poblacionales de pacientes hospitalizados), los sistemas de notificación de incidentes, las bases de datos administrativas y otros como el *debriefing* u observación directa de incidentes. Sin embargo, unos requieren mucho tiempo para su puesta en práctica⁸ (revisión de historias) y otros son muy poco exhaustivos⁹ (notificación de incidentes y bases de datos administrativas).

En respuesta a la necesidad de un acercamiento al problema de la seguridad del paciente de manera más eficiente, el Institute of Healthcare Improvement (IHI) desarrolló el método *Global Trigger Tool* o herramienta *trigger* (HT)¹⁰. La HT es una revisión de historias clínicas dirigida, ya sea manualmente o de forma automática, que se centra en la búsqueda de parámetros, situaciones clave o «gatillos» (*trigger*) que con frecuencia se asocian con uno o varios tipos de EA y son útiles para su detección. Este método no pretende identificar todos y cada uno de los EA existentes en una historia clínica, sino que, debido a la limitación de tiempo para la revisión de las historias clínicas, está diseñado para detectar indirectamente la presencia de EA y observar su cambio en el tiempo. La HT se viene utilizando de manera creciente en los hospitales de los Estados Unidos y del Reino Unido. En comparación con otros sistemas, la HT puede examinar la frecuencia y los tipos de problemas relacionados con medicamentos, y evaluar la seguridad de los medicamentos longitudinalmente^{8,11,12}.

El objetivo de este estudio fue evaluar el rendimiento de la HT en la identificación de EA en pacientes adultos hospitalizados en un servicio de medicina interna. Adicionalmente, se elaboró una herramienta resumida mediante una selección de *triggers* para mejorar la capacidad predictiva de presencia o ausencia de EA.

Método

Estudio transversal de una muestra aleatoria realizada por ordenador de informes clínicos asociados a un proceso de hospitalización durante el año 2013 en el Hospital Santa Bárbara (Puertollano, Ciudad Real, España), para la detección de EA mediante revisión sistemática y búsqueda de los EA o de los *triggers* incluidos en una lista previamente elaborada para encontrar EA relacionados. La búsqueda de *triggers* se acompañó de la detección de posibles EA en la historia clínica. La elaboración del panel final de *triggers*, así como la búsqueda y la determinación de la existencia de EA, ya se han detallado en otro lugar¹³. La revisión fue realizada por un médico que siguió un proceso sistemático de revisión de la historia clínica para la extracción de información (fig. 1).

Cuando se encontró un *trigger* se revisaron las partes relevantes de la historia para buscar EA que pudieran asociarse a ese

trigger. Por ejemplo, la detección de transfusión sanguínea *trigger* puede poner de relieve la existencia de una sobredosificación de acenocumarol *EA*, de una hemorragia por la realización de un procedimiento invasivo *EA* o de una perforación intestinal por isquemia *no EA*. Los EA detectados sin *trigger* asociado, fruto de la revisión sistemática de la historia clínica, fueron igualmente incluidos en el registro y categorizados.

Se consideró que el EA que pudiera ser detectado podía haberse producido en cualquier momento del pasado (días, meses...).

Análisis estadístico

Se utilizaron estadísticos descriptivos de todas las variables, con determinación de medidas de centralización (media y porcentaje) y dispersión (desviación estándar e intervalo de confianza del 95% [IC95%]).

Para evaluar el rendimiento de cada *trigger* se determinó su valor predictivo positivo (VPP), tomando como referencia el total de los EA detectados mediante la herramienta *trigger* y los EA detectados mediante la revisión sistemática de la historia clínica. Se determinó igualmente el VPP global de la HT. Se estableció el número necesario de alertas, definido como el número de *trigger* detectados necesarios para encontrar un EA.

El modelo de predicción para la propuesta de optimización de la herramienta se realizó mediante regresión logística binaria con el método *forward conditional*, introduciendo como variable dependiente la aparición de EA y como variables independientes las que obtuvieron significación estadística en el análisis bivariado comparativo o que podrían tener una implicación clínicamente plausible. Los resultados del modelo se presentaron en forma de *odds ratio* (OR) e IC95%. El análisis de la calibración del modelo, o grado en que la ecuación encaja en los datos originales, se realizó mediante el estadístico de Hosmer-Lemeshow. El poder discriminatorio del modelo se evaluó mediante el concepto de área bajo la curva ROC (*receiver-operator characteristics*), esto es, la relación de sensibilidad y especificidad del modelo resultante con respecto a la detección de los EA. La variabilidad de los EA en este modelo resumido será determinada por el cálculo de la R² de Nagelkerke.

La base de datos se realizó con Microsoft Excel (v 14.4.7), y el programa estadístico utilizado fue SPSS Statistics (v20.0). Se consideró que las diferencias eran estadísticamente significativas con $p < 0,05$.

El estudio fue valorado favorablemente por el Comité Ético de Investigación Clínica del Hospital General de Ciudad Real.

Resultados

Descripción de los triggers

En la tabla 1 se resumen las características de la muestra. Se revisaron 291 historias clínicas y se detectaron 562 *triggers* en 103 pacientes, de los cuales 163 estuvieron implicados en la detección de un EA. Varios *triggers* pudieron detectar un mismo EA, por lo que, si bien el número neto de EA detectados fue de 149, el sumatorio de los EA encontrados por los *triggers* individualmente considerados fue de 163. En la tabla 2 se muestra el listado de *triggers* que detectaron al menos un EA, y su rendimiento. El tiempo medio requerido para la revisión de las historias clínicas fue de 5 minutos y 16 segundos.

El *trigger* más frecuentemente detectado (15,83%) fue «B.6. Prednisona u otro corticoide», que sin embargo no encontró ningún EA. Los siguientes *triggers* detectados, por orden descendente, fueron «B.5. Laxante o enema» (6,58%), «A.8. Agitación» (5,33%) y «B.1. Antieméticos» (5,33%). Algunos *triggers* no fueron detectados ninguna vez: «A.4. Infarto agudo de miocardio en paciente

Download English Version:

<https://daneshyari.com/en/article/7510899>

Download Persian Version:

<https://daneshyari.com/article/7510899>

[Daneshyari.com](https://daneshyari.com)