

Machine learning en anestesia. Avances de hoy para la anestesia del mañana

Anesthesia and machine learning

Agustín Núñez^{1,*}, Samer Tawfiq^{2,3}, Andrés Polit¹

¹ Interno de Medicina, Universidad Autónoma de Chile. Santiago, Chile.

² Anestesiólogo, Universidad de Ciencias Médicas de La Habana. La Habana, Cuba.

³ Validado Corporación Nacional Autónoma de Certificación de Especialidades Médicas (CONACEM). Santiago, Chile.

Esta investigación no contó con apoyo financiero.

Fecha de recepción: 31 de mayo de 2023 / Fecha de aprobación: 03 de julio de 2023

ABSTRACT

Artificial intelligence (AI) is concerned with developing systems that perform tasks that typically require human intelligence. Machine learning (ML) is an important branch of AI and has significant applications in medicine. These applications have allowed advancements in anesthesiology, where algorithms capable of recognizing patterns in arterial waveforms and predicting episodes of hypotension have been developed, reducing postoperative pain and monitoring anesthesia. All of these tools are capable of assisting physicians in event prevention and decision-making. However, it is important to note that, up to now, ML-based tools cannot replace the clinical judgment of an anesthesiologist due to potential biases inherent in initial programming.

Key words: Artificial intelligence, anesthesia, intraoperative complications, intraoperative monitoring, machine learning

RESUMEN

La inteligencia artificial (IA) se ocupa de desarrollar sistemas que realizan tareas que normalmente requieren inteligencia humana. El machine learning (ML) es una rama importante de la IA y tiene aplicaciones significativas en medicina. Estas aplicaciones han permitido avances en anestesiología, donde se han desarrollado algoritmos capaces de reconocer patrones en las ondas arteriales y predecir episodios de hipotensión, disminuir el dolor posoperatorio y monitorear la anestesia. Todas estas herramientas son capaces de asistir a los médicos en la prevención de eventos y en la toma de decisiones. Sin embargo, es importante tener en cuenta que, hasta ahora, las herramientas basadas en ML no pueden reemplazar el juicio clínico del anestesiólogo debido a posibles sesgos inherentes a la programación inicial.

Palabras clave: Inteligencia artificial, anestesia, complicaciones intraoperatorias, monitoreo intraoperatorio, machine learning.

Introducción

La inteligencia artificial (IA) es una rama de la informática que se encarga de desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana[1]. Dentro de la IA, una rama importante es el aprendizaje automático o machine learning (ML), el cual corresponde al proceso en el que programas informáticos avanzados procesan grandes conjuntos de datos de muchas fuentes y descubren patrones y

asociaciones que se luego se utilizan para codificar (o aprender) un modelo matemático en capas (algoritmo)[2]. Dentro de sus funciones se encuentran procesar grandes conjuntos de datos de múltiples fuentes y descubrir patrones y asociaciones para crear modelos matemáticos que pueden ser aplicados a nuevos datos para predecir resultados precisos y confiables[2]. Las tareas principales del ML en el campo de la medicina incluyen la clasificación, que consiste en diferenciar una enfermedad a partir de una historia clínica o imagen; la producción, que im-

anunezibanez@gmail.com

*ORCID: <https://orcid.org/0009-0003-8988-6054>

ISSN: 0716-4076



plica la estimación del riesgo de eventos clínicos futuros; y el descubrimiento, que se enfoca en encontrar nuevos usos para medicamentos existentes[2]. Estas aplicaciones han permitido que el ML se desarrolle en diferentes áreas de la medicina. Dentro de estas áreas, ha destacado su utilidad la radiología, pudiendo mejorar la precisión y eficiencia en el diagnóstico de enfermedades. El uso de ML en radiología se basa en la capacidad del algoritmo para aprender de grandes conjuntos de datos de imágenes radiológicas y hacer predicciones precisas sobre la presencia o ausencia de enfermedades o condiciones específicas[3]. Por ejemplo, se ha utilizado en la detección de cáncer de mama, obteniendo resultados comparables con radiólogos y mejorando la detección cuando es utilizado por ellos[4]. Además, el ML también se utiliza en la investigación médica, lo que permite a los estudiantes acceder a información valiosa y mantenerse actualizados en los avances de la medicina[5]. El progreso de la IA y el ML ha sido tan significativo que la revista *New England Journal of Medicine* (NEJM) ha lanzado recientemente una nueva revista enfocada exclusivamente en la aplicación de estas tecnologías en el campo de la medicina, en respuesta al creciente interés y relevancia que ha adquirido esta nueva área[6]. A pesar del rápido avance tecnológico, especialmente en el campo del ML, la comunidad médica y de anestesia ha mostrado una mayor latencia en su adaptación, incluso en lo que se refiere a enfoques bien establecidos como la Medicina Basada en la Evidencia (MBE), que ha existido por décadas. Teniendo en cuenta lo anterior, resulta importante examinar los estudios que buscan incorporar y validar estas tecnologías emergentes en la práctica habitual de la anestesia y ver qué beneficios les pueden ofrecer a los pacientes.

Metodología

Se llevó a cabo una revisión no sistemática mediante la plataforma PubMed utilizando el motor de búsqueda MedLine con el objetivo de evaluar los beneficios que presenta para los pacientes el uso de herramientas basadas en ML en la práctica de la anestesia. Para la búsqueda, se utilizaron los operadores booleanos de: ((machine learning) OR (artificial intelligence) OR (Deep learning)) AND ((anesthesia). Se estableció como filtro la categoría de Clinical Trial o Randomized Controlled Trial y se limitó la búsqueda a artículos publicados en los últimos 5 años. No se estableció una restricción en cuanto al idioma de los artículos. Se identificaron un total de 46 artículos que cumplían inicialmente con la búsqueda. Se realizó una revisión de abstracts de los artículos, de los cuales se excluyó aquellos que no se traban de temas de anestesia, que no incluían el uso de machine learning en su metodología y que no utilizaron AI o ML dentro de la variable a comparar. Se obtuvo así un total de 10 artículos (n = 10) que cumplieron con los criterios de búsqueda establecidos.

Usos de machine learning en anestesia

La aplicación de la tecnología de ML ha permitido avances significativos en la práctica de la anestesia, demostrando que esta área no se ha quedado atrás en términos de innovación. Se ha investigado ampliamente el uso del ML en la anestesiología, como algoritmos entrenados en reconocer patrones de

ondas arteriales y lograr predecir los episodios de hipotensión intraoperatorios[10]. Por otro lado, se han elaborado diversas herramientas que buscan estimar con mayor precisión la profundidad anestésica, en comparación con el índice bispectral (BIS), que es el método clásico utilizado[7]. También, se han producido algoritmos que tienen como objetivo clasificar los electroencefalogramas (EEG) de los pacientes bajo anestesia en estados de conciencia e inconsciencia[8]. Asimismo, se han desarrollado algoritmos que ayudan a la estimación de una laringoscopia difícil[9]. Por otro lado, no obstante, son escasos los estudios que han comprobado y contrastado dichas herramientas innovadoras con la práctica clínica en pacientes. Por lo tanto, en los estudios clínicos que están utilizando y comparando estas herramientas en la práctica clínica convencional, los cuales se encuentran resumidos en la Tabla 1.

Prevención de eventos de hipotensión

Al programar un algoritmo de ML, una de sus principales capacidades es la de predecir eventos a partir de la información proporcionada por diversas bases de datos. Es por esta razón que se han desarrollado diversas herramientas de ML que buscan predecir eventos de hipotensión, los cuales se definen como una presión arterial media (PAM) inferior a 65 mmHg por al menos un minuto[11]. En el ámbito de los estudios que buscan evaluar la utilidad estas herramientas, se encuentra el estudio del algoritmo Hypotension Prediction Index (HPI)[10]. El propósito era desarrollar un algoritmo capaz de predecir la hipotensión con una anticipación de 15, 10 o 5 minutos antes de su ocurrencia, con sensibilidades y especificidades que variaban del 87% al 92%, dependiendo del tiempo de predicción[10]. Dicho algoritmo, utilizó bases de datos de curvas de presión arterial invasiva como base de datos. Posteriormente, aparece el primer estudio piloto que buscaba validar clínicamente dicho algoritmo. En el estudio clínico realizado por Maheshwari K. et al[12] se utilizó el HPI como método predictivo de los eventos de hipotensión intraoperatoria en pacientes sometidos a cirugías no cardíacas con monitoreo invasivo de la presión arterial. Sin embargo, los resultados del estudio no mostraron una reducción significativa en dichos eventos. No obstante, un nuevo estudio clínico aleatorizado surgió con el propósito de volver a validar el algoritmo HPI. Este estudio, llamado Hypotension Prediction Trial (HYPE), buscaba verificar la efectividad de un sistema de alertas tempranas basado en el HPI, como una medida proactiva para prevenir eventos de hipotensión[11]. En este estudio se observó que el uso del sistema de alarmas tempranas se asoció con un menor tiempo de hipotensión en los pacientes, en comparación con aquellos que no lo utilizaron[11]. Por otro lado, también se ha estudiado el uso del algoritmo HPI en pacientes con monitoreo no invasivo de la presión arterial. El estudio de Maheshwari et al.[13], se encontró que el algoritmo HPI tenía la capacidad de predecir eventos de hipotensión arterial durante el transcurso de la cirugía con una anticipación de 5, 10 y 15 minutos, logrando una sensibilidad y especificidad entre el 75% y el 86% según el momento analizado. Esto amplía las posibilidades de uso del algoritmo HPI, no solo como herramienta intraoperatoria en monitoreo invasivo, sino también con métodos no invasivos para la medición de la presión arterial. Recientemente, se ha investigado sobre la eficacia del HPI como predictor de eventos de hipotensión posoperatoria. No

Tabla 1

Autor	Año	Tipo de estudio	Outcome	Resultados
Maheshwari K. et al[12]	2020	RCT	Prevención hipotensión intraoperatoria	El grupo que utilizó HPI no presentó menor incidencia de eventos de hipotensión intraoperatoria a menos que los anestesiólogos intervinieran
Wijnberge M. et al[11]	2020	RCT	Prevención hipotensión intraoperatoria	El grupo que utilizó HPI presentó una menor duración de hipotensión intraoperatoria en comparación con el grupo control
Maheshwari et al[13]	2021	CT	Prevención hipotensión intraoperatoria	El grupo que hizo uso del HPI mostró sensibilidades y especificidades que oscilaron entre el 75% y el 86%, dependiendo del momento en que se realizó el análisis previo al evento
Schenk J. et al[14]	2021	RCT	Prevención hipotensión posoperatoria	Sin diferencias en tiempo de hipotensión posoperatoria entre el grupo que utilizó HPI y el grupo control
Meijer F. et al[18]	2020	RCT	Disminución dolor posoperatorio	Menor dolor posoperatorio a los 90 minutos en el grupo que recibió analgesia intraoperatoria guiada por NoL
Fuica R. et al[19]	2022	RCT	Disminución dolor posoperatorio	Menor dolor posoperatorio a los 90 minutos en el grupo que recibió analgesia intraoperatoria guiada por NoL
Gu Y. et al[20]	2019	CT	Monitoreo anestésico	Logró diferenciar entre el estado despierto, anestesia leve y anestesia general con una precisión de 86,4%, 73,6% y 84,4% respectivamente
Hayase K. et al[21]	2020	CT	Monitoreo anestésico	Lograron un coeficiente de correlación de Pearson (R) de 0,87 ($p < 0,0001$) cuando se comparó el diagrama de Poincaré de 20 a -30 hz con el monitoreo BIS
In Chan J. et al[22]	2021	CT	Identificar sitio de punción para bloqueo ecoguiado	La tasa de éxito del primer intento para la anestesia espinal fue del 79,1% (38/48), seguida de un segundo intento exitoso del 12,5%, un tercer intento del 4,2% y un cuarto intento del 4,2%

*RCT: Random Controlled Trial; **CT: Controlled trial; ***HPI: Hypotension Prediction Index; ****NoL: Índice de nivel de nocicepción.

obstante, un estudio realizado por Schenk J. et al.[14], concluyó que esta herramienta no es útil para predecir dichos eventos, por lo que su uso se limita al ámbito intraoperatorio.

Disminución de dolor posoperatorio

Los algoritmos de ML son altamente versátiles y pueden utilizarse con diversas bases de datos para reconocer relaciones significativas entre fenómenos diversos. Uno de los ejemplos más relevantes es el desarrollo y validación de algoritmos que buscan medir el nivel de nocicepción intraoperatorio, permitiendo así reducir el dolor posoperatorio. El índice de nivel de nocicepción (NoL) es un índice de nocicepción basado en la combinación no lineal de la frecuencia cardíaca, la variabilidad de la frecuencia cardíaca, la amplitud de la onda pletismográfica, la conductancia de la piel, las fluctuaciones de la conductancia de la piel y sus derivadas temporales[15]. Esta herramienta impulsada por el ML ha sido sometida a pruebas previas en estudios preliminares[16],[17] y continúa con su desarrollo hasta la fecha. Dentro de los estudios que continúan validando y comparando el NoL, se encuentra el estudio de Meijer F et al.[18], que ha demostrado una disminución en el dolor posoperatorio a los 90 minutos en el grupo en el que se utilizó NoL. Esto se logró sin la necesidad de aumentar el uso de analgesia intraoperatoria en comparación con el grupo de control. Recientemente, un estudio realizado por Fuica R et

al.[19], también ha demostrado una disminución significativa del dolor posoperatorio, sin necesidad de un aumento en el uso de opioides intra o posoperatorios. Estos resultados refuerzan la validez del NoL como un parámetro efectivo para reducir el dolor posoperatorio inmediato.

Monitoreo del nivel anestésico

Los algoritmos de ML han demostrado su capacidad para entrenar y reconocer patrones en el monitoreo de la profundidad anestésica. Esto ha llevado al desarrollo de algoritmos que ayudan en la distinción de los diferentes planos anestésicos, proporcionando un valioso apoyo en este proceso. El objetivo del estudio realizado por Gu Y et al.[20], fue validar un algoritmo de ML capaz de distinguir entre los diferentes niveles de anestesia en pacientes. Los resultados obtenidos con el algoritmo mostraron que éste logró distinguir con precisión entre el estado despierto, la anestesia leve y la anestesia general. En concreto, la precisión alcanzada fue del 86,4%, 73,6% y 84,4% respectivamente. Además, se encontró una correlación significativa entre las predicciones del algoritmo y la interpretación del BIS, con un coeficiente de correlación de 0,892. Por otro lado, los resultados del estudio indicaron que la precisión del algoritmo en la identificación del estado de anestesia profunda fue limitada, alcanzando solamente 14%. Se ha llevado a cabo otro estudio por parte de Hayase K et al.[21], con el

objetivo de combinar dos diagramas de Poincaré y algoritmos de ML para identificar diferentes niveles de anestesia y compararlos con el BIS. Los resultados establecieron una relación con coeficiente de correlación de Pearson (R) de 0,87 ($p < 0,0001$) cuando se comparó el diagrama de Poincaré de 20 a -30 hz, demostrando validez en la detección de las distintas fases del plano anestésico y comparable con los métodos más convencionales.

Otros usos

Los diferentes métodos de programación de algoritmos de ML tienen un gran potencial en diversas áreas de la anestesia, incluyendo la detección de estructuras a través de la ecografía. Un estudio de In Chan J et al.[22], demuestra que una herramienta basada en ML puede ser utilizada para localizar el punto de inserción de la aguja de anestesia neuroaxial L3/L4 en pacientes obesos, con una tasa de éxito del 79,1% en el primer intento. Esto demuestra la utilidad de estas herramientas para mejorar el diagnóstico de imágenes y ayudar en procedimientos anestésicos. Por otro lado, se ha seguido investigando la capacidad de los algoritmos de ML para predecir eventos posoperatorios. En particular, el trabajo de King C et al.[23], quienes están llevando a cabo un estudio en fase tres utilizando en una herramienta basada en ML para predecir diferentes eventos posoperatorios, como delirio posoperatorio, falla renal, falla respiratoria y mortalidad a los 30 días. Además, instalaron un sistema de telemedicina llamado Torre de Control de Anestesia (ACT) que utiliza estas mediciones para asistir en la toma de decisiones intraoperatorias.

Discusión

El uso del ML en anestesia es un tema fascinante que ha despertado gran interés en la comunidad médica y científica en los últimos años. El ML posee la capacidad de desarrollar de algoritmos que pueden aprender de los datos y mejorar su rendimiento con el tiempo. Esto lo hace especialmente útil para el análisis de grandes cantidades de datos, como las señales de EEG y la información hemodinámica del paciente durante la anestesia.

Uno de los mayores desafíos en la anestesia es la individualización del tratamiento para cada paciente, lo que requiere una comprensión profunda de las necesidades únicas del paciente y la capacidad de ajustar los tratamientos en tiempo real. La capacidad del ML para procesar grandes cantidades de datos y encontrar patrones ocultos en ellos puede ser de gran ayuda en este aspecto.

Sin embargo, es importante tener en cuenta que el uso del machine learning en la anestesia también plantea desafíos y preocupaciones. Uno de los mayores desafíos es la necesidad de datos de alta calidad y grandes cantidades de datos para entrenar los algoritmos de ML. También hay preocupaciones sobre la interpretación de los resultados de los algoritmos de ML y la necesidad de que los anesthesiólogos entiendan cómo se están tomando las decisiones. Además, es importante tener en cuenta que, hasta el momento, el uso de herramientas basadas en ML no puede sustituir el criterio clínico del anesthesiólogo en ninguna circunstancia. Esto se debe a que dichas herramientas

pueden contener sesgos inherentes a la persona que las programó inicialmente.

Conclusiones

En conclusión, la implementación del ML en la anestesiología tiene el potencial de mejorar la calidad de la atención médica y disminuir los riesgos de complicaciones. Sin embargo, es fundamental abordar los desafíos y preocupaciones que surgen al utilizar esta tecnología y garantizar que los anesthesiólogos comprendan cómo se están tomando las decisiones basadas en los algoritmos de ML. En general, el uso de ML en anestesiología tiene el potencial de mejorar significativamente la calidad del cuidado del paciente y debería seguir siendo objeto de investigación y desarrollo.

Referencias

1. Ruseel S, Norving P. Artificial Intelligence: A modern approach [Internet]. 2009. Available from: www.PlentyofeBooks.net
2. Scott IA. Demystifying machine learning: a primer for physicians. Vol. 51, Internal Medicine Journal. John Wiley and Sons Inc; 2021. p. 1388–400.
3. Erickson BJ, Korfiatis P, Akkuz Z, Kline TL. Machine learning for medical imaging. *Radiographics*. 2017;37(2):505–15. <https://doi.org/10.1148/rg.2017160130> PMID:28212054
4. Rodríguez-Ruiz A, Krupinski E, Mordang JJ, Schilling K, Heywang-Köbrunner SH, Sechopoulos I, et al. Detection of breast cancer with mammography: effect of an artificial intelligence support system. *Radiology*. 2019 Feb;290(2):305–14. <https://doi.org/10.1148/radiol.2018181371> PMID:30457482
5. Carin L. On Artificial Intelligence and Deep Learning Within Medical Education. *Acad Med*. 2020 Nov 1;95(11S Association of American Medical Colleges Learn Serve Lead):S10–1. <https://doi.org/10.1097/ACM.0000000000003630>.
6. Beam AL, Drazen JM, Kohane IS, Leong TY, Manrai AK, Rubin EJ. Artificial Intelligence in Medicine [Internet]. *N Engl J Med*. 2023 Mar;388(13):1220–1. Available from: <http://www.nejm.org/doi/10.1056/NEJMe2206291> <https://doi.org/10.1056/NEJMe2206291> PMID:36988598
7. Mirsadeghi M, Behnam H, Shalbf R, Jelveh Moghadam H. Characterizing Awake and Anesthetized States Using a Dimensionality Reduction Method. *J Med Syst*. 2016 Jan;40(1):13. <https://doi.org/10.1007/s10916-015-0382-4> PMID:26573650
8. Shalbf A, Saffar M, Sleigh JW, Shalbf R. Monitoring the depth of anesthesia using a new adaptive neurofuzzy system. *IEEE J Biomed Health Inform*. 2018 May;22(3):671–7. <https://doi.org/10.1109/JBHI.2017.2709841> PMID:28574372
9. Moustafa MA, El-Metainy S, Mahar K, Mahmoud Abdel-magied E. Mahmoud Abdel-magied E. Defining difficult laryngoscopy findings by using multiple parameters: A machine learning approach. *Egypt J Anaesth*. 2017 Apr;33(2):153–8. <https://doi.org/10.1016/j.ejja.2017.02.002>.
10. Hatib F, Jian Z, Buddi S, Lee C, Settels J, Sibert K, et al. Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis. *Anesthesiology*. 2018 Oct;129(4):663–74. <https://doi.org/10.1097/ALN.0000000000002300> PMID:29894315

11. Wijnberge M, Geerts BF, Hol L, Lemmers N, Mulder MP, Berge P, et al. Effect of a Machine Learning-Derived Early Warning System for Intraoperative Hypotension vs Standard Care on Depth and Duration of Intraoperative Hypotension During Elective Noncardiac Surgery: The HYPE Randomized Clinical Trial. *JAMA*. 2020 Mar;323(11):1052–60. <https://doi.org/10.1001/jama.2020.0592> PMID:32065827
12. Maheshwari K, Shimada T, Yang D, Khanna S, Cywinski JB, Irefin SA, et al. Hypotension Prediction Index for Prevention of Hypotension during Moderate- to High-risk Noncardiac Surgery. *Anesthesiology*. 2020 Dec;133(6):1214–22. <https://doi.org/10.1097/ALN.0000000000003557> PMID:32960954
13. Maheshwari K, Buddi S, Jian Z, Settels J, Shimada T, Cohen B, et al. Performance of the Hypotension Prediction Index with non-invasive arterial pressure waveforms in non-cardiac surgical patients. *J Clin Monit Comput*. 2021 Feb;35(1):71–8. <https://doi.org/10.1007/s10877-020-00463-5> PMID:31989416
14. Schenk J, Wijnberge M, Maaskant JM, Hollmann MW, Hol L, Immink RV, et al. Effect of Hypotension Prediction Index-guided intraoperative haemodynamic care on depth and duration of postoperative hypotension: a sub-study of the Hypotension Prediction trial. *Br J Anaesth*. 2021 Nov;127(5):681–8. <https://doi.org/10.1016/j.bja.2021.05.033> PMID:34303491
15. Ben-Israel N, Kliger M, Zuckerman G, Katz Y, Edry R. Monitoring the nociception level: a multi-parameter approach. *J Clin Monit Comput*. 2013 Dec;27(6):659–68. <https://doi.org/10.1007/s10877-013-9487-9> PMID:23835792
16. Martini CH, Boon M, Broens SJ, Hekkelman EF, Oudhoff LA, Buddeke AW, et al. Ability of the nociception level, a multi-parameter composite of autonomic signals, to detect noxious stimuli during propofol-remifentanyl anesthesia. *Anesthesiology*. 2015 Sep;123(3):524–34. <https://doi.org/10.1097/ALN.0000000000000757> PMID:26154185
17. Edry R, Recea V, Dikust Y, Sessler DI. Preliminary Intraoperative Validation of the Nociception Level Index: A Noninvasive Nociception Monitor. *Anesthesiology*. 2016 Jul;125(1):193–203. <https://doi.org/10.1097/ALN.0000000000001130> PMID:27171828
18. Meijer F, Honing M, Roor T, Toet S, Calis P, Olofsen E, et al. Reduced postoperative pain using Nociception Level-guided fentanyl dosing during sevoflurane anaesthesia: a randomised controlled trial. *Br J Anaesth*. 2020 Dec;125(6):1070–8. <https://doi.org/10.1016/j.bja.2020.07.057> PMID:32950246
19. Fuica R, Krochek C, Weissbrod R, Greenman D, Freundlich A, Gozal Y. Reduced postoperative pain in patients receiving nociception monitor guided analgesia during elective major abdominal surgery: a randomized, controlled trial. *J Clin Monit Comput*. 2022. PMID:35976578
20. Gu Y, Liang Z, Hagihira S. Use of multiple EEG features and artificial neural network to monitor the depth of anesthesia. *Sensors (Switzerland)*. 2019 Jun 1;19(11). <https://doi.org/10.3390/s19112499>.
21. Hayase K, Hayashi K, Sawa T. Hierarchical Poincaré analysis for anaesthesia monitoring. *J Clin Monit Comput*. 2020 Dec;34(6):1321–30. <https://doi.org/10.1007/s10877-019-00447-0> PMID:31863245
22. In Chan JJ, Ma J, Leng Y, Tan KK, Tan CW, Sultana R, et al. Machine learning approach to needle insertion site identification for spinal anesthesia in obese patients. *BMC Anesthesiol*. 2021 Oct;21(1):246. <https://doi.org/10.1186/s12871-021-01466-8> PMID:34663224
23. King CR, Abraham J, Kannampallil TG, Fritz BA, Ben Abdallah A, Chen Y, et al. Protocol for the effectiveness of an anesthesiology control tower system in improving perioperative quality metrics and clinical outcomes: the tectonics randomized, pragmatic trial. *F1000 Res*. 2020;•••:8.