



# Grandes modelos de lenguaje en la educación médica basada en competencias

Luis Ramirez-Garcia<sup>(1)</sup>, Mario Arturo Luna Lamas<sup>(1)</sup>

## Resumen

La Inteligencia Artificial (IA), a través de los grandes modelos de lenguaje, LLM (del inglés, *Large Languages Models*), ofrece nuevas oportunidades en el campo educativo y necesita planes estratégicos para ser aprovechada. La incorporación de este sistema se compromete a aumentar la efectividad y exactitud en la valoración de habilidades clínicas adaptadas a la enseñanza médica. El uso de estas herramientas bien entrenadas podría aumentar la imparcialidad y uniformidad en la evaluación, preparando a los alumnos para los desafíos actuales mediante una formación personalizada. Es importante que los profesores cuenten con acceso a tecnología avanzada y la utilicen de manera efectiva en la enseñanza, lo que implica formación continua y mejora de las instalaciones educativas. El Examen Clínico Objetivo Estructurado (ECO) se ha posicionado como una herramienta crucial, siendo reconocido como el estándar principal para evaluar habilidades clínicas del alumno. En medicina educativa, se han investigado últimamente aplicaciones de IA como BioBERT, Med-PaLM2 y GPT-4. La comunicación natural entre el estudiante y un sistema de inteligencia artificial podría generar una experiencia más envolvente si es bien entrenada. El ECO y sus variantes tienen la capacidad de convertirse en herramientas más efectivas, creando un ambiente de aprendizaje que se adapte de manera más adecuada a los retos actuales donde será cada vez más difícil que el alumno en formación pueda acceder suficiente tiempo a los hospitales

e interactuar con pacientes reales. Es necesario incorporar la inteligencia artificial en la enseñanza médica, y superar los obstáculos técnicos y prácticos, con la finalidad de mejorar la educación y adaptar la experiencia de aprendizaje, para garantizar un futuro tecnológicamente avanzado, pero también ético, inclusivo y humano.

**Palabras clave:** ECOE, inteligencia artificial, simulación.

## Abstract

*Artificial Intelligence (AI), through LLMs (Large Languages Models), offers new opportunities in the educational field and needs strategic plans to be exploited. The incorporation of this system is committed to increase the effectiveness and accuracy in assessing clinical skills and adapting medical education. The use of these well-trained tools could increase fairness and uniformity in assessment, preparing students for today's challenges through personalized training. It is important that teachers have access to advanced technology and use it effectively in teaching, which implies continuous training and improvement of educational facilities. The Objective Structured Clinical Examination (OSCE) has positioned itself as a crucial tool, being recognized as the leading standard for assessing student clinical skills. In educational medicine, AI applications such as BioBERT, Med-PaLM2 and GPT-4 have*

---

### Filiación institucional:

(1) Facultad de Medicina Matamoros, Instituto de Ciencias y Estudios Superiores de Tamaulipas

**Autor de correspondencia:** Luis Ramirez-Garcia | investigacionmat2001@icest.edu.mx



*been investigated lately. Natural communication between the learner and an AI system could generate a more immersive experience if well trained. ECOE and its variants have the potential to become more effective tools, creating a learning environment that is more suited to today's challenges where it will be increasingly difficult for the trainee to access enough time in hospitals and interact with real patients. It is necessary to incorporate artificial intelligence into medical education, and overcome technical and practical obstacles, to improve education and adapt the learning experience, to ensure a future that is technologically advanced, but also ethical, inclusive, and humane.*

**Keywords:** OSCE, artificial intelligence, simulation.

## Introducción

La inteligencia artificial (IA), representada por los grandes modelos de lenguaje (LLM), abre un horizonte prometedor y desafiante en la educación que requiere de propuestas equilibradas y estratégicas. Para incorporarlas en la educación médica es esencial diseñar sistemas que no solo aprovechen su capacidad para personalizar y enriquecer el aprendizaje, sino que también aborden las implicaciones éticas y sociales a su uso. Los LLM que utilizan el procesamiento de lenguaje natural como BioBER (Lee et al., 2020) T, Med-PaLM2 o el Chatbot GPT-4 (Waisberg et al., 2023) entre otros, tienen el potencial de revolucionar la manera en que se enseña y se evalúan las competencias educativas, facilitando el aprendizaje (Mendiola, 2023).

Para que su incorporación en la educación sea sostenible, debe de ir acompañada de una crítica constructiva de cómo estos avances podrían complementar y reforzar los métodos pedagógicos tradicionales y así, asegurar que se mantenga la empatía y otras habilidades socioemocionales en la educación, esto requiere del compromiso con la integración y revisión de estas, así mismo de la colaboración estrecha entre docentes y alumnos

para establecer los medios adecuados que preparen a los futuros médicos.

Su integración ofrece un panorama prometedor, enfocado a mejorar la eficacia y precisión en la evaluación de competencias clínicas, así como la personalización de la educación médica basada en competencias, que se encuentra en constante cambio (Goldhamer et al., 2024; Ryan et al., 2023; Schumacher et al., 2024).

Both y col. sugieren estas herramientas de procesamiento de lenguaje natural para evaluar subcompetencias clínicas como: el conocimiento médico, la práctica basada en sistemas y las habilidades interpersonales y de comunicación establecidos en programas de educación en medicina como lo es el ACGME (*Accreditation Council for Graduate Medical Education*) para guiar a los residentes a desarrollar planes de acción para mejorar sub competencias específicas (Booth et al., 2023) (Spadafore et al., 2024).

El empleo de dichas herramientas no solo incrementa la imparcialidad y la coherencia en la valoración, sino que también capacita a los alumnos para afrontar desafíos del mundo real con una enseñanza más integral y personalizada. La capacitación se convierte en un aspecto fundamental en donde es necesario cerrar la brecha digital y comprender la manera de cómo adoptar estas herramientas de manera eficiente en las prácticas pedagógicas, lo que permita paulatinamente actualizar los planes de estudios donde se incluyan, tanto para interactuar con ellas de manera eficaz, como para analizar y debatir sus impactos en la sociedad (Han et al., 2019; Johnston, 2018).

Este proceso implica mejorar constantemente las habilidades profesionales y mejorar la infraestructura educativa para proporcionar una educación integral, atractiva tecnológicamente, crítica y éticamente informada, transformando el proceso de enseñanza-aprendizaje para preparar a los estudiantes para abordar los desafíos actuales de manera activa. En este campo, se puede explorar cómo la tecnología complementa la enseñanza tradicional. La transición muestra un

compromiso con la innovación educativa y resalta la necesidad de preparar a los estudiantes para los entornos clínicos complejos y cambiantes que encontrarán en su futura carrera profesional (Han et al., 2019).

## Implementación de los grandes modelos de lenguaje en la educación médica

**Exámenes Personalizados:** Los modelos de lenguaje pueden ser programados para evaluar de manera precisa las competencias y necesidades específicas de aprendizaje de cada estudiante. Esto permite la generación de exámenes a medida que son tanto justos como desafiantes, asegurando una evaluación precisa del progreso individual.

**Feedback Automático:** Implementando estos modelos, es posible ofrecer realimentación inmediata y personalizada sobre las respuestas de los estudiantes en exámenes y asignaciones. Este enfoque facilita una revisión continua y permite a los estudiantes corregir errores en tiempo real, una práctica esencial para el aprendizaje efectivo en medicina.

**Análisis de Respuestas Abiertas:** En la educación médica, donde las respuestas a menudo requieren un análisis exhaustivo y crítico, los modelos de lenguaje pueden proporcionar evaluaciones automáticas de respuestas abiertas. Esto ayuda a identificar el conocimiento factual y la capacidad del estudiante para aplicar dicho conocimiento en contextos prácticos.

**Simulaciones Interactivas:** La integración de modelos de lenguaje en simulaciones médicas facilita la creación de escenarios dinámicos y realistas. Esto permite a los estudiantes desarrollar habilidades diagnósticas y de toma de decisiones en un entorno controlado, simulando interacciones con pacientes y casos clínicos complejos.

**Optimización de Currículos:** Mediante el análisis de datos de rendimiento estudiantil los modelos de lenguaje pueden ayudar a identificar

áreas de mejora en los currículos existentes. Esto asegura que los contenidos educativos estén alineados con las necesidades de aprendizaje y los estándares profesionales actuales.

**Asistentes Virtuales para Enseñanza:** Estos asistentes, potenciados por modelos de lenguaje, pueden proporcionar apoyo constante y personalizado, facilitando el acceso a información, guía en el estudio y aclaración de dudas fuera del ambiente de aula tradicional.

**Plataforma de Tutorías Inteligentes:** Al adaptarse específicamente a las necesidades individuales, estas plataformas ofrecen una experiencia de tutoría más eficiente y dirigida, potenciando el aprendizaje autónomo y dirigido por competencias.

**Evaluaciones Adaptativas:** Utilizando modelos de lenguaje para ajustar la dificultad de las preguntas en tiempo real, las evaluaciones adaptativas pueden medir con mayor precisión las competencias del estudiante, promoviendo así un aprendizaje más profundo y efectivo.

Es necesario definir el potencial de los LLM con lo último en los procesos educativos especialmente en la formación de los alumnos de medicina, por mencionar un ejemplo, a través de la simulación clínica; que es una enseñanza práctica de la educación, donde el alumno se desarrolla en un ambiente seguro y ha demostrado ser efectiva para adquirir habilidades clínicas complejas e integrar conocimientos, aumentando el grado de retención de lo aprendido cuando se compara con la metodología tradicional (Figura 1).

En este contexto, en los escenarios de simulación clínica como el Examen Clínico Objetivo Estructurado (ECO) se les da un enfoque realista para que el alumno sienta la confianza de participar activamente; generalmente se utilizan dispositivos, personas o incluso el entorno (Bradley, 2006; Johannesson, 2012; Salas-Medina et al., 2017)

Es fundamental contar con una planificación y diseño adecuado, además de los recursos necesarios para alcanzar los objetivos de evaluación al realizar un ECOE lo que permita describir las competencias a evaluar mediante el uso de rúbricas



**Figura 1.** Usos potenciales de los grandes modelos de lenguaje en la educación médica basada en competencias.

para analizar las mejoras en los estudiantes y reforzar el contenido teórico con retroalimentación personalizada (Bradley, 2006; Johannesson, 2012; Salas-Medina et al., 2017).

Por definición, el ECOE es un método de evaluación de las competencias clínicas del alumno de pregrado en un escenario simulado, se compone de varias estaciones en las que se interactúa con un participante o actor previamente entrenado, al que se le denomina "paciente estandarizado" con el que se reproduce una consulta médica a través de la imitación de un caso clínico previamente definido (R. M. Harden, 2016; R. M. G. Harden et al., 1975; Hopwood et al., 2020).

Los ECOEs pueden emplearse en evaluaciones diagnósticas al comienzo de un curso o de un programa educativo para determinar el nivel de aprendizaje de los estudiantes y ajustar las estrategias de enseñanza - aprendizaje a sus requerimientos. Después, se utilizan en evaluaciones formativas para proporcionar realimentación constante y asistir a los estudiantes en su mejora. Al final, se convierten en sumativos al determinar si los estudiantes alcanzan un nivel de competencia clínica necesario para avanzar en su educación (R. M. Harden, 2016), su uso permite evaluar diversas competencias como: el conocimiento médico, las habilidades de atención al paciente y



procedimientos, el profesionalismo, las habilidades interpersonales y de comunicación, el aprendizaje basado en la práctica y mejora, y la práctica basada en sistemas y debido a su flexibilidad, no se limitan al campo de la medicina (Bogo et al., 2012; Espinosa-Vázquez et al., 2020).

En la evaluación formativa y sumativa es fundamental evaluar el desempeño, el desarrollo de habilidades psicosociales y diversas competencias antes de la práctica profesional. Los ECOEs se han convertido en una herramienta clave para este fin, siendo considerados el estándar en la evaluación de habilidades clínicas (Martínez-González et al., 2016, 2017; Mejía et al., 2014). Cada estación simula escenarios que el futuro profesional enfrentará en su día a día. En los centros de enseñanza por simulación se pueden realizar múltiples acciones como: la anamnesis, el examen físico, el diagnóstico preciso y el tratamiento apropiado de un paciente, lo que implica una simulación óptima entre el paciente y alumno en formación, es decir, hay una relación interpersonal paciente-examinado.

Si bien, de manera tradicional el ECOE se basa en pacientes o actores que representan casos clínicos en un contexto presencial, el avance de la simulación clínica y las nuevas tecnologías educativas permiten diversificar las estrategias para evaluar competencias prácticas a través de este. Estas nuevas tecnologías emplean simuladores de alta y mediana fidelidad, realidad virtual o videos pregrabados para representar escenarios clínicos con los cuales, el estudiante aprende sin exponer al paciente real a algún riesgo.

Además, plataformas digitales como *Zoom*, posibilitan adaptar el ECOE a modalidades virtuales sincrónicas, donde los estudiantes interactúan en tiempo real con pacientes y evaluadores en línea (Desai et al., 2023).

La simulación y los grandes modelos de lenguaje aumentan las opciones para implementar el ECOE de forma más flexible, al brindar nuevos ambientes de aprendizaje práctico y evaluación de destrezas clínicas.

Este instrumento brinda una realimentación valiosa para que los estudiantes identifiquen áreas

de oportunidad y mejoren su formación antes de ejercer su práctica profesional.

Las teorías educativas subyacentes a los ECOEs, como: la teoría del aprendizaje basado en competencias y la simulación educativa, proporcionan un marco sólido para integrar innovaciones tecnológicas.

Estas teorías enfatizan la importancia de un análisis integral y contextualizado de las habilidades clínicas y socioemocionales, algo que los LLM pueden potenciar significativamente (Chimea et al., 2020; Hurtubise & Roman, 2014; Richardson et al., 2021; Wass et al., 2001).

Recientemente, se han comenzado a explorar aplicaciones de la inteligencia artificial y los LLM como BERT o transformadores generativos pre-entrenados (del inglés *Generative Pre-training Transformer*) GPT en medicina educativa (Pereira et al., 2023). Por un lado, estos LLM se pueden utilizar para automatizar la generación de casos clínicos complejos, que servirán como base para desarrollar las estaciones de evaluación y analizar una amplia cantidad de datos. Estos modelos de lenguaje entrenados permiten producir escenarios e historias de pacientes con mayor variedad y flexibilidad.

La interacción natural del lenguaje entre el estudiante y un modelo de Inteligencia Artificial podría brindar una experiencia más inmersiva y eliminar sesgos que provienen de "actores" (Weiwen Xue et al., 2023). Al aprovechar estas capacidades, el uso de estos modelos de lenguaje y programas de chat de voz que funjan como pacientes estandarizados dentro de los ECOEs, pueden transformarse en herramientas más dinámicas y eficientes para facilitar un entorno de aprendizaje que responde mejor a los desafíos actuales.

No obstante, es necesario validar rigurosamente estas aplicaciones para garantizar la calidad técnica y ética en la evaluación de competencias clínicas a través de la simulación de un ECOE.

La IA presenta grandes retos para matizar los aspectos emocionales y garantizar la estandarización en las respuestas y el uso de rúbricas.

Aún quedan incógnitas para que representen una innovación prometedora para el futuro en la enseñanza médica (Entre ellos está la Simulación ECOE-Digital entrenamiento del GPT y manuscrito en preparación), la evaluación de habilidades prácticas en ciencias de la salud, la aceptación por parte de estudiantes y docentes, y la capacidad de replicar fielmente situaciones clínicas complejas.

Es imperante abrirse a nuevos escenarios de como los LLM pueden enriquecer la educación y personalizar la experiencia en la adquisición

de competencias específicas e inclusive de la adaptación a casos clínicos en lenguajes ajenos al español que ayuden a las nuevas generaciones de estudiantes a enfrentar los desafíos con confianza y una profunda comprensión ética. Depende de los docentes mantener un equilibrio entre la innovación tecnológica y los valores que conforman la educación. Su integración en la educación médica enfrenta desafíos técnicos significativos y limitaciones prácticas que requieren atención detallada.



Figura 2. Una Inteligencia en Salud en donde se engloban las aplicaciones potenciales de los LLM en el futuro la atención médica.

## Una inteligencia en salud

Entre estos desafíos se encuentra la necesidad de desarrollar una plataforma tecnológica sólida que englobe las diversas necesidades para llegar al objetivo general de “Una sola Inteligencia en Salud” (Figura 2).

La propuesta de crear una “inteligencia en salud” global a través de la implementación de grandes modelos de lenguaje en el sistema de salud, abre un horizonte de posibilidades. Este enfoque no solo mejoraría la eficiencia y precisión en múltiples aspectos de la atención médica, sino que también, podría democratizar el acceso a servicios de salud de alta calidad. A continuación, algunas de las principales aplicaciones:

**Diagnóstico Asistido por IA:** Los modelos de lenguaje, integrados con sistemas de inteligencia artificial (IA), pueden analizar rápidamente grandes volúmenes de datos médicos para asistir en el diagnóstico. Esto incluye el reconocimiento de patrones en imágenes médicas, análisis de historiales clínicos y síntomas para sugerir diagnósticos preliminares, reduciendo la carga sobre los profesionales médicos y aumentando la precisión diagnóstica.

**Tratamientos Personalizados:** La personalización de tratamientos basada en análisis predictivos y de datos epidemiológicos locales puede ser facilitada por modelos de lenguaje. Estos sistemas pueden sugerir regímenes de tratamiento ajustados a las características individuales de cada paciente, como perfil genético/epigenético mediante análisis complejos bioinformáticos, condiciones preexistentes y respuestas a tratamientos anteriores, optimizando los resultados de salud.

**Gestión de Cuidados de Salud:** La integración de modelos de lenguaje en la gestión de cuidados puede mejorar la coordinación entre diferentes servicios y proveedores de salud, optimizar la utilización de recursos y automatizar tareas administrativas. Esto podría conducir a una atención más integrada y continua, especialmente para pacientes con condiciones crónicas.

**Educación y Formación Médica:** Los modelos de lenguaje pueden apoyar la educación médica a través de exámenes personalizados, retroalimentación automática y simulaciones interactivas con aplicaciones de Chats de voz. Además, pueden mantener a los profesionales médicos actualizados sobre las últimas investigaciones y protocolos clínicos.

**Atención Preventiva y Monitoreo Remoto:** Los modelos de lenguaje pueden jugar un papel crucial en la atención primaria a la salud al analizar datos continuos de salud recogidos por dispositivos portátiles y otros monitores remotos. Esto permite la detección temprana de posibles problemas de salud personales, locales o nacionales. Además, la educación preventiva personalizada podría ser entregada a los pacientes, adaptada a sus riesgos y necesidades específicas.

## Conclusión

El desafío es comprometernos a utilizar estos grandes modelos de lenguaje de manera que respeten y mejoren las actitudes y aptitudes de todos los estudiantes y docentes, y asegurar así, que el futuro de la educación sea no solo tecnológicamente avanzado entre la colaboración humano-IA como “socios cognitivos”, sino también inclusivo, ético y humano.

## Referencias bibliográficas

1. Bogo, M., Regehr, C., Katz, E., Logie, C., Tufford, L., & Litvack, A. (2012). Evaluating an Objective Structured Clinical Examination (OSCE) Adapted for Social Work. *Research on Social Work Practice*, 22(4), 428–436. <https://doi.org/10.1177/1049731512437557>
2. Booth, G. J., Ross, B., Cronin, W. A., McElrath, A., Cyr, K. L., Hodgson, J. A., Sibley, C., Ismawan, J. M., Zuehl, A., Slotto, J. G., Higgs, M., Haldeman,



- M., Geiger, P., & Jardine, D. (2023). Competency-Based Assessments: Leveraging Artificial Intelligence to Predict Subcompetency Content. *Academic Medicine*, 98(4), 497–504. <https://doi.org/10.1097/ACM.00000000000005115>
3. Bradley, P. (2006). The history of simulation in medical education and possible future directions. *Medical Education*, 40(3), 254–262. <https://doi.org/10.1111/J.1365-2929.2006.02394.X>
  4. Chimea, T. La, Kanji, Z., & Schmitz, S. (2020). Assessment of clinical competence in competency-based education PRACTICAL IMPLICATIONS OF THIS RESEARCH. *Can J Dent Hyg*, 54(2), 83–91.
  5. Desai, P. V., Howell, H. B., McGrath, M., Ramsey, R., Lebowitz, J., Trogen, B., Cha, C., Pierce, K. A., & Zabar, S. (2023). Zoom Objective Structured Clinical Exams: Virtually the Same as the Real Thing? *Academic Pediatrics*, 23(2), 483–488. <https://doi.org/10.1016/j.acap.2022.11.004>
  6. Espinosa-Vázquez, O., Sánchez-Mendiola, M., Leenen, I., Martínez-González, A., & Mx, C. (2020). Evaluación del desarrollo de la competencia clínica en odontopediatría con el examen clínico objetivo estructurado. *Investigación En Educación Médica*, 9(34), 53–62. <https://doi.org/10.22201/facmed.20075057e.2020.34.19198>
  7. Goldhamer, M. E. J., Pusic, M. V., Nadel, E. S., Co, J. P. T., & Weinstein, D. F. (2024). Promotion in Place: A Model for Competency-Based, Time-Variable Graduate Medical Education. *Academic Medicine : Journal of the Association of American Medical Colleges*. <https://doi.org/10.1097/ACM.00000000000005652>
  8. Han, E. R., Yeo, S., Kim, M. J., Lee, Y. H., Park, K. H., & Roh, H. (2019). Medical education trends for future physicians in the era of advanced technology and artificial intelligence: an integrative review. *BMC Medical Education*, 19(1). <https://doi.org/10.1186/S12909-019-1891-5>
  9. Harden, R. M. (2016). Revisiting “Assessment of clinical competence using an objective structured clinical examination (OSCE).” *Medical Education*, 50(4), 376–379. <https://doi.org/10.1111/MEDU.12801>
  10. Harden, R. M. G., Downie, W. W., Stevenson, M., & Wilson, G. M. (1975). Assessment of clinical competence using objective structured examination. *British Medical Journal*, 1(5955), 447. <https://doi.org/10.1136/BMJ.1.5955.447>
  11. Hopwood, J., Myers, G., & Sturrock, A. (2020). Twelve tips for conducting a virtual OSCE. *Med Teach*, 43(6), 1–4. <https://doi.org/10.1080/0142159x.2020.1830961>
  12. Hurtubise, L., & Roman, B. (2014). Competency-based curricular design to encourage significant learning. *Current Problems in Pediatric and Adolescent Health Care*, 44(6), 164–169. <https://doi.org/10.1016/J.CPPEDS.2014.01.005>
  13. Johannesson, E. (2012). Learning manual and procedural clinical skills through simulation in health care education.
  14. Johnston, S. C. (2018). Anticipating and Training the Physician of the Future: The Importance of Caring in an Age of Artificial Intelligence. *Academic Medicine : Journal of the Association of American Medical Colleges*, 93(8), 1105–1106. <https://doi.org/10.1097/ACM.00000000000002175>
  15. Lee, J., Yoon, W., Kim, S., Kim, D., Kim, S., So, C. H., & Kang, J. (2020). BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*, 36(4), 1234–1240. <https://doi.org/10.1093/BIOINFORMATICS/BTZ682>
  16. Martínez-González, A., Lifshitz-Guinzberg, A., Trejo-Mejía, J. A., Torruco-García, U., Fortoul-Van Der Goes, T. I., Flores-Hernández, F., Peña-Balderas, J., Martínez-Franco, A. I., Hernández-Nava, A., Elena-González, D., & Sánchez-Mendiola, M. (2017). Evaluación diagnóstica y formativa de competencias en estudiantes de medicina a su ingreso al internado médico de pregrado. *Gaceta Medica de Mexico*, 153(1), 6–15.
  17. Martínez-González, A., Sánchez-Mendiola, M., Méndez-Ramírez, I., & Trejo-Mejía, J. A. (2016). Grado de competencia clínica de siete generaciones de estudiantes al término del internado médico de pregrado. *Gaceta Médica de México*, 152(5), 679–687. [www.anmm.org.mx](http://www.anmm.org.mx)



18. Mejía, J. A. T., González, A. M., Ramírez, I. M., López, S. M., Pérez, L. C. R., & Mendiola, M. S. (2014). Evaluación de la competencia clínica con el examen clínico objetivo estructurado en el internado médico de la Universidad Nacional Autónoma de México. *Gaceta Medica de Mexico*, 150(1), 8–17.
19. Mendiola, M. S. (2023). ChatGPT y educación médica: ¿estrella fugaz tecnológica o cambio disruptivo? *Investigación En Educación Médica*, 12(46), 5–10. <https://doi.org/10.22201/FM.20075057E.2023.46.23511>
20. Pereira, D. S. M., Falcão, F., Nunes, A., Santos, N., Costa, P., & Pêgo, J. M. (2023). Designing and building OSCEBot ® for virtual OSCE - Performance evaluation. *Medical Education Online*, 28(1). <https://doi.org/10.1080/10872981.2023.2228550>
21. Richardson, D., Kinnear, B., Hauer, K. E., Turner, T. L., Warm, E. J., Hall, A. K., Ross, S., Thoma, B., & Van Melle, E. (2021). Growth mindset in competency-based medical education. *Medical Teacher*, 43(7), 751–757. <https://doi.org/10.1080/0142159X.2021.1928036>
22. Ryan, M. S., Lomis, K. D., Deiorio, N. M., Cutrer, W. B., Pusic, M. V., & Caretta-Weyer, H. A. (2023). Competency-Based Medical Education in a Norm-Referenced World: A Root Cause Analysis of Challenges to the Competency-Based Paradigm in Medical School. *Academic Medicine : Journal of the Association of American Medical Colleges*, 98(11), 1251–1260. <https://doi.org/10.1097/ACM.0000000000005220>
23. Salas-Medina, D. L., Isela Martínez-Martínez, K., King, S., María Méndez-Puga, A., & Sahagún-Padilla, M. Á. (2017). Escenarios de simulación como estrategia de aprendizaje: la experiencia Save Stan.
24. Schumacher, D. J., Kinnear, B., Carraccio, C., Holmboe, E., Busari, J. O., van der Vleuten, C., & Lingard, L. (2024). Competency-based medical education: The spark to ignite healthcare's escape fire. *Medical Teacher*, 46(1). <https://doi.org/10.1080/0142159X.2023.2232097>
25. Spadafore, M., Yilmaz, Y., Rally, V., Chan, T. M., Russell, M., Thoma, B., Singh, S., Montiero, S., Pardhan, A., Martin, L., Monrad, S. U., & Woods, R. (2024). Using Natural Language Processing to Evaluate the Quality of Supervisor Narrative Comments in Competency-Based Medical Education. *Academic Medicine : Journal of the Association of American Medical Colleges*. <https://doi.org/10.1097/ACM.0000000000005634>
26. Waisberg, E., Ong, J., Masalkhi, M., Kamran, S. A., Zaman, N., Sarker, P., Lee, A. G., & Tavakkoli, A. (2023). GPT-4: a new era of artificial intelligence in medicine. *Irish Journal of Medical Science*, 192(6), 3197–3200. <https://doi.org/10.1007/S11845-023-03377-8>
27. Wass, V., Van Der Vleuten, C., Shatzer, J., & Jones, R. (2001). Assessment of clinical competence. *Lancet*, 357(9260), 945–949. [https://doi.org/10.1016/S0140-6736\(00\)04221-5](https://doi.org/10.1016/S0140-6736(00)04221-5)
28. Weiwen Xue, V., Lei, P., Cho, W. C., & William Cho, C. C. (2023). The potential impact of ChatGPT in clinical and translational medicine. *Clinical and Translational Medicine*, 13(3), e1216. <https://doi.org/10.1002/CTM2.1216>