



Modelos predictivos de vigilancia epidemiológica en salud pública usando la salud digital y los determinantes sociales y estructurales de la salud(sdoh): revisión sistemática.

Predictive models of epidemiological surveillance in public health using digital health and social and structural determinants of health (sdoh): systematic review.

Recibido: 18/11/2024- Aceptado: 31/08/2025 - Publicado: 08/10/2025

Autores

Deiber Armando Pinzón Castro *

Médico especialista en Medicina Aplicada a la Actividad física y el Deporte. Epidemiólogo Clínico.
Centro de Servicios de Salud-SENA
Medellín - Colombia
deiberpinzon@gmail.com

Diana Catalina Arcila Echavarría

Ingeniera Química. Magister en Ingeniería. PhD en Biotecnología.
Centro de Servicios de Salud-SENA
Medellín - Colombia
darcilae@sena.edu.co

Sandra M. Arroyave Espinal

Enfermera profesional.
Centro de Servicios de Salud-SENA
Medellín - Colombia
arroyaveespinalsandramilena@gmail.com

Jor F. Maturana Cuesta

Administrador en Salud con énfasis en Gestión Sanitaria Ambiental. Profesional en salud pública.
Centro de Servicios de Salud-SENA.
Medellín - Colombia
macues.jor@gmail.com

Brodny Y. Herrera López

Profesional en Gerencia de sistemas de información en salud. Especialista en mercadeo. Magister en mercadeo con énfasis en servicios y experiencias.
Centro de Servicios de Salud-SENA
Medellín - Colombia
byherreral@eafit.edu.co

Álvaro A. Araque Fernández

Médico especialista en ginecología y obstetricia.
Centro de Servicios de Salud-SENA.
Medellín - Colombia
aaraquefernandez@gmail.com

*Autor de correspondencia



RESUMEN

Contexto: Los determinantes sociales y estructurales de la salud son aquellas estructuras sociales y económicas que median las desigualdades en salud, que están relacionadas entre sí y se superponen para facilitar o limitar un desenlace, se incluyen los entornos sociales y físicos, servicios de salud, factores sociales. Se pueden dividir en dos categorías: individuales o específicos del paciente, como educación, empleo o vivienda; y determinantes comunitarios, que miden el ambiente en el cual se desenvuelve el individuo o socioeconómicas como la contaminación del aire, características de la vivienda, tasa de desempleo, y aquí es importante resaltar la importancia del registro de estos en los diferentes modelos de historia clínica electrónica. Se concluye que se requiere herramientas con amplia difusión y uso interinstitucional, que facilite la inclusión de las variables que hagan referencia a estos determinantes sociales y que puedan ayudar a identificar factores de riesgo para poblaciones especiales.

Objetivo: evaluar de forma crítica, qué tipo de modelos predictivos se han desarrollado para predecir desenlaces en salud, usando herramientas digitales para el registro y procesamiento de la información y que incluyan los SDOH.

Métodos: Esta es una revisión sistemática de la literatura, de tipo narrativo, brinda una visión crítica de los resultados encontrados respecto a estudios de pronóstico, que usaron herramientas digitales para su construcción y que incluyeron determinantes sociales y estructurales de la salud para la predicción del riesgo. Para su elaboración, se han seguido las recomendaciones de la declaración PRISMA.

Resultados: Las primeras búsquedas se realizaron en abril de 2022, utilizando los términos MeSH: “determinantes sociales”, “pronóstico” y “tecnologías en salud”, “salud pública” y los operadores booleanos AND y OR según necesidad, se usaron las bases de datos PubMed, Cochrane, además de los servidores de prepublicación bioRxiv y medRxiv, también se realizó búsqueda en Google Scholar. Posteriormente se procedió a realizar una revisión por título en cada base de datos para identificar artículos relacionados con las palabras clave y que pudieran ser incluidos en la revisión sistemática, eliminando 1020 artículos, quedando para evaluación por Abstrac y texto completo 45 artículos, de los cuales fueron eliminados 40 artículos adicionales por no encontrar relación con el tema de la revisión sistemática y uno por ser una carta al editor de una revista. Se encontraron 2 revisiones sistemáticas que tenían tema similar a esta revisión pero que no tenían en cuenta la misma profundidad respecto al tema. Por lo anterior se decidió incluir en la revisión sistemática 5 artículos de pronóstico.

Conclusiones: Esta revisión sistemática permite concluir que los modelos predictivos que incorporan SDOH, junto con herramientas digitales para la recolección de información, mejoran significativamente su capacidad predictiva y precisión. Los mejores resultados se observan cuando se incluyen tanto los SDOH individuales como los comunitarios.

Palabras clave: Interpretación de datos, salud pública, predicción de riesgo, diseño de investigación, modelos, vigilancia epidemiológica.



ABSTRACT

Context: The social and structural determinants of health are those social and economic structures that mediate health inequalities, which are interrelated and overlapping to facilitate or limit an outcome. Including social and physical environments, health services and social factors, they can be divided into two categories: individual or patient-specific, such as education, employment, or housing; and community determinants, which measure the environment in which the individual develops or socioeconomic factors such as air pollution, housing characteristics, unemployment rate, and here it is important to highlight the importance of recording these in the different models of electronic medical records. It is concluded that tools with wide dissemination and inter-institutional use are required, which facilitate the inclusion of variables that refer to these social determinants and that can help identify risk factors for special populations.

Objective: To critically evaluate what kind of predictive models have been developed to predict health outcomes, using digital tools for recording and processing information and including SDOH.

Methods: This is a systematic review of narrative literature, providing a critical view of the results found with respect to prognostic studies, which used digital tools for their construction and included social and structural determinants of health for risk prediction. For its preparation, the recommendations of the PRISMA declaration have been followed.

Results: The first searches were conducted in April 2022, using the MeSH terms: "social determinants", "forecast" and "health technologies", "public health" and the Boolean operators AND and OR as needed, the PubMed, Cochrane databases were used, in addition to the bioRxiv and medRxiv prepublication servers, Google Scholar was also used. Subsequently, a review by title was carried out in each database to identify articles related to the keywords and that could be included in the systematic review, eliminating 1020 articles, selecting 45 articles for evaluation by abstract and full text, of which 40 additional articles were eliminated for not finding a relationship with the topic of the systematic review and one for being a letter to the editor of a journal. We found 2 systematic reviews that had a similar theme to our review but did not take into account the same depth regarding the topic. Therefore, it was decided to include 5 prognostic articles in this systematic review.

Conclusions: This systematic review concludes that predictive models that incorporate SDOH, along with digital tools for data collection, significantly improve their predictive capacity and accuracy. The best results are observed when both individual and community SDOH are included.

Keywords: Data interpretation, public health, risk prediction, research design, models, epidemiological surveillance.



INTRODUCCIÓN

La vigilancia epidemiológica tiene como objetivo identificar riesgos en salud tempranamente, buscando intervenir y disminuir el impacto de estas condiciones en la población, por lo anterior es importante poder identificar cuales variables potenciales están asociadas a un riesgo específico o una condición de salud que, mediante una intervención temprana, pueda mitigar su impacto poblacional (1-5). La investigación relacionada con pronóstico tiene gran importancia en esta área del conocimiento, ya que mediante este tipo de estudios es posible identificar factores pronósticos para desenlaces en salud y posteriormente validar estos trabajos en diferentes poblaciones, buscando hallar causalidad entre factores pronóstico y un desenlace (1, 2, 5-7). Para poder desarrollar un modelo predictivo (pronóstico), se debe llevar a cabo una adecuada selección, definición, medición y categorización de las variables a incluir; definir sus posibles interacciones, número de variables, tamaño de muestra, enfatizar en la importancia de la calidad del dato, pruebas estadísticas a utilizar, validación, calibración del modelo, discriminación y utilidad (1, 7, 8).

Los modelos epidemiológicos utilizados para dar respuesta a este tipo de preguntas orientadas al pronóstico, son los estudios observacionales tipo cohorte, los cuales incluyen a grupos de individuos con características en común, se realiza seguimiento en un tiempo determinado, posteriormente con la información recolectada es posible observar la aparición de eventos o un desenlace que se quiera evaluar, a partir de esto podremos realizar estimaciones sobre la probabilidad de ocurrencia del evento en el tiempo, se podrán comparar diferentes cohortes, lo que permitirá establecer la fuerza de asociación de las variables pronóstico con el desenlace (1, 7, 9-11). Este tipo de trabajos de investigación deben ceñirse a unas normas de realización, publicación y validación, para que sus resultados sean válidos y puedan ser generalizables, de lo contrario no estarían aportando valor a la investigación clínica (6, 7, 11-13). Dos conceptos claves en este tipo de modelo de investigación son el

factor de riesgo que se puede definir como una exposición ambiental o un factor genético, que está asociado a una probabilidad y el factor pronóstico que es el elemento que se expresa subclínicamente, pero se asocia en mayor o menor probabilidad con el desenlace, en este documento estará representado por los determinantes sociales y estructurales de la salud (SDOH, por su sigla en inglés), los cuales son considerados claves en los desenlaces en salud, ya que pueden facilitar o dificultar un resultado clínico como el control de una enfermedad crónica o por el contrario su descompensación clínica (9, 14, 15).

Los SDOH son aquellas estructuras sociales y económicas que median las desigualdades en salud, que están relacionadas entre sí y se superponen para facilitar o limitar un desenlace, se incluyen los entornos sociales y físicos, servicios de salud, factores sociales (16-18). Estos SDOH son muy amplios y pueden dividirse en diferentes categorías y es claro que cuando aborda un desenlace específico, este está asociado a unos determinantes puntuales que van a tener peso en la ocurrencia o no del desenlace en salud, y se pueden dividir en dos categorías: individuales o específicos del paciente, como educación, empleo o vivienda; y determinantes comunitarios, que miden el ambiente en el cual se desenvuelve el paciente o socioeconómicas como la contaminación del aire, características de la vivienda, tasa de desempleo, y aquí es importante resaltar la importancia del registro de estos en los diferentes modelos de historia clínica electrónica, ya que son promotores del riesgo y aumentan la susceptibilidad individual a la enfermedad en los sistemas de atención clínica y de salud pública, cada país cuenta con sus propios determinantes sociales y su contexto individual (17, 19). Chen y colaboradores realizaron una revisión sistemática (20), buscando integrar los registros electrónicos de salud que facilitan el análisis e integración de datos individuales o comunitarios, ubicados en un entorno específico y en una línea de tiempo concreta, al integrar los determinantes sociales de la salud, con estos registros, se pudo identificar factores o variables que influyen en el estado de salud del individuo y que facilitan enfoques ascendentes y descendentes de atención, que



pueden mejorar la eficacia de la misma, llevando a la correcta utilización de recursos. Algunos determinantes sociales como la pobreza, el desempleo e incluso las tasas de contaminación del aire, contribuyen mínimamente a estos modelos predictivos (15, 20). Existen modelos específicos para desenlaces especiales, que tienen asociación directa con algunos determinantes sociales: actividades sexuales de alto riesgo se asocian con la predicción del riesgo de VIH, tuberculosis, la edad, el consumo de sustancias y los trastornos mentales se asocian con la predicción de los intentos de suicidio, pero no se ha evidenciado determinantes que estén asociados con múltiples desenlaces, se encuentra una brecha en el conocimiento, una falta de claridad sobre cuales determinantes tiene mayor peso sobre un desenlace específico y si realmente su modificación tendrá el impacto esperado en el desenlace (10, 21, 22). En esta revisión los autores resaltan la limitación que se tiene en el registro de información de estos determinantes sociales, lo cual limita la eficacia de estos modelos predictivos, facilitando la presencia de sesgos de selección y de análisis (20, 21). Se concluye que se requiere herramientas con amplia difusión y uso interinstitucional, que facilite la inclusión de las variables que hagan referencia a estos determinantes sociales y que puedan ayudar a identificar factores de riesgo para poblaciones especiales (20, 21, 23). Es importante resaltar que según como se intervenga o modifique estos determinantes sociales, se podrá lograr impactar el desenlace estudiado o evaluado y de esta manera lograr disminuir las inequidades en salud (21, 24, 25).

Diferentes países tienen grandes mejoras en su cobertura en salud, sin embargo, actualmente estos países están presentando una disminución de las tasas de crecimiento económico, mostrando un aumento en costos de cobertura en salud, debido a que su población de adultos mayores ha aumentado, y existen altas expectativas en salud pública, generando una amenaza al sistema sanitario (23, 24). La Organización Mundial de la Salud (OMS) resalta la necesidad de desarrollar mecanismos que faciliten el apoyo del uso de la evidencia científica en investigación mediante la creación de guías de

práctica clínica, evaluación de nuevas tecnologías en salud y nuevas políticas en salud, enfatizando en la importancia de la calidad de los estudios científicos como alternativa para mejorar la legitimidad y la eficacia del proceso de toma de decisiones (23, 24). Actualmente se cuenta con nuevas tecnologías informáticas que facilitan la captación de grandes volúmenes de información de un gran número de variables poblacionales, que pueden ser procesadas y analizadas utilizando la inteligencia artificial (IA), machine learning o Big Data, al incluir este tipo de variables en modelos predictivos aplicados a la salud pública, se puede construir modelos de predicción más ajustados a la realidad y aplicar los resultados a políticas de salud pública (2, 26-29). Científicos, médicos, gobierno e instituciones han generado y están facilitando esta información para que sea de acceso público y pueda ser utilizada con este fin, mediante un procesamiento adecuado y la construcción de algoritmos de predicción que sean robustos, precisos y que puedan tener gran impacto en la salud de nuestras regiones, con esto se quiere cambiar de un modelo centrado en la enfermedad a un modelo con un enfoque preventivo, que incluya factores individuales como sociales para prevenir la aparición de la enfermedad; aunque en muchos países se cuenta con sistemas de monitoreo epidemiológico, estos terminan respondiendo a la aparición de la enfermedad o el evento de interés, sin embargo, podría decirse que no se ha contado con un modelo predictivo que permita anticipar la aparición de los distintos eventos o que se utilice adecuadamente por los entes gubernamentales para intervenir una población y garantizar la disminución en prevalencia e incidencia de un desenlace en salud determinado (6, 15, 26, 30-35). El objetivo de esta revisión sistemática es evaluar de forma crítica, qué tipo de modelos predictivos se han desarrollado para predecir desenlaces en salud, usando herramientas digitales para el registro y procesamiento de la información y que incluyan los SDOH, identificando modelos que se acerquen a la predicción del riesgo en salud pública, desde concepciones que vayan más allá de la prestación de servicios de salud o el enfoque morbicentrico. Actualmente no se tiene claridad sobre la fuerza de asociación de los SDOH con los desenlaces en salud



en los diferentes modelos predictivos.

METODOLOGÍA

Esta revisión sistemática de la literatura, de tipo narrativo, brinda una visión crítica de los resultados encontrados respecto a estudios de pronóstico, que usaron herramientas digitales para su construcción y que incluyeron SDOH para la predicción del riesgo. Para su elaboración, se han seguido las recomendaciones de la declaración PRISMA(36), se incluyeron estudios que desarrollaron y/o validaron modelos predictivos multivariados, para predecir desenlaces en salud (hospitalización, reingresos hospitalarios, utilización total de servicios en salud y mortalidad), en personas mayores de 18 años, sin discriminación por sexo, utilizando herramientas de la salud digital y SDOH, solo se tuvieron en cuenta estudios observacionales prospectivos o retrospectivos, que utilizaran los SDOH para predecir desenlaces en salud. Se analizó el riesgo de sesgos

de cada una de las publicaciones incluidas en esta revisión, usando la herramienta PROBAST(37). Se utilizaron las bases de datos (PUBMED y Cochrane), además de los servidores de prepublicación bioRxiv y medRxiv, se realizó búsqueda en Google Scholar, se tuvieron en cuenta estudios publicados a partir del año 2000 hasta la actualidad, ya que es un tema que no cuenta con mucha investigación al respecto, se usaron los términos MESH en inglés: salud pública, herramientas digitales, modelos predictivos y determinantes sociales. Estas bases de datos fueron elegidas, ya que en ellas se logra encontrar el 97% de las publicaciones indexadas, además tienen amplia cobertura en ciencias biomédicas y tecnología. Se incluyeron artículos en idioma inglés, no se tuvo en cuenta el factor de impacto de la revista de la publicación. Se excluyeron artículos que publicaran resultados en animales, publicación de resultados parciales, artículos duplicados. La Tabla 1 muestra los sitios, estrategias de búsqueda y resultados obtenidos.

TABLA 1. Búsqueda bibliográfica (fecha ultima búsqueda, 02/11/2022).

BASE DE DATOS	TÉRMINOS Y ESTRATEGIA DE BÚSQUEDA	NÚMERO DE RESULTADOS TOTALES
Medline-PubMed	((("PUBLIC HEALTH") AND ("DIGITAL TOOLS"))) AND/OR ("PREDICTIVE MODELS") AND ("SOCIAL DETERMINANTS")	26
Cochrane	((("PUBLIC HEALTH") AND ("DIGITAL TOOLS"))) AND/OR ("PREDICTIVE MODELS") AND ("SOCIAL DETERMINANTS")	0
BioRxiv	((("PUBLIC HEALTH") AND ("DIGITAL TOOLS"))) AND ("PREDICTIVE MODELS") AND ("SOCIAL DETERMINANTS") and published between "January 1, 2010 and November 1, 2022"	208
MedRxiv	((("PUBLIC HEALTH") AND ("DIGITAL TOOLS"))) AND ("PREDICTIVE MODELS") AND ("SOCIAL DETERMINANTS") and published between "January 1, 2010 and November 1, 2022"	778
Google Scholar	((("PUBLIC HEALTH") AND ("DIGITAL TOOLS"))) AND/OR ("PREDICTIVE MODELS") AND ("SOCIAL DETERMINANTS")	52




Selección de estudios y recopilación de datos

El proceso llevado a cabo para identificar los documentos elegibles para la revisión se muestra en la Figura 1. Diagrama de flujo PRISMA en cuatro niveles(36). Inicialmente dos revisores independientes, leyeron los títulos de los documentos encontrados en cada una de las bases de datos relacionadas en la tabla 1, se eliminaron los artículos que no estaban relacionados con las palabras utilizadas en las búsqueda, posteriormente se evaluó los resúmenes de los artículos

preseleccionados para definir el cumplimiento de los criterios de inclusión y exclusión garantizando que los artículos seleccionados aportaran a dar respuesta a la pregunta planteada en esta revisión y que incluyeran determinantes sociales, herramientas digitales, modelos pronóstico y resultados en salud pública. Los revisores llevaron a cabo una discusión sobre desacuerdos en la inclusión o exclusión de artículos y un tercero intervino en caso de ser necesario en artículos específicos en caso de desacuerdo.

Figura 1. Diagrama de flujo PRISMA en cuatro niveles(36).



Fuente: Elaboración propia.



RESULTADO

Búsqueda inicial y sistemática

Las primeras búsquedas se realizaron en abril de 2022, utilizando los términos MeSH: “determinantes sociales”, “pronóstico” y “tecnologías en salud”, en la base de datos PubMed, donde se encontraron 87 artículos asociados a esta búsqueda, con el fin de hacer más precisa la búsqueda, se incluyó los términos entre comillas, se adicionó “salud pública” y los operadores booleanos AND y OR según necesidad, se extendió la búsqueda a otras bases de datos (Cochrane), además de los servidores de prepublicación bioRxiv y medRxiv, se realizó búsqueda en Google Scholar. Los resultados de estas búsquedas están relacionados en la tabla 1. Búsqueda bibliográfica: PubMed (26), Cochrane (0), bioRxiv (208), medRxiv (778), Google Scholar (52). Posteriormente se procedió a realizar una revisión por título en cada base de datos para identificar artículos relacionados con las palabras clave y que pudieran ser incluidos en la revisión sistemática, eliminando el siguiente número de artículos por base de datos (PubMed 19, MedRxiv 751, BioRxiv 203 , Google Scholar 47), luego de esta selección inicial fueron eliminados 1020 artículos, quedando para evaluación por Abstrac y texto completo 45 artículos, de los cuales fueron eliminados 40 artículos de la siguiente manera (Google Scholar 5, PubMed 2, MedRxiv 27, BioRxiv 5, duplicados 1), lo anterior por no encontrar relación con el tema de la revisión sistemática y uno por ser una carta al editor de una revista. Se encontraron 2 revisiones sistemáticas que tenían tema similar a esta revisión pero que no tenían en cuenta la misma profundidad respecto al tema. Por lo anterior se decidió incluir en la revisión sistemática 5 artículos de pronóstico (Figura 1. Diagrama de flujo PRISMA en cuatro niveles).

Los artículos incluidos en esta revisión fueron sintetizados en la tabla 2. Características de los estudios revisados. Donde se presenta una síntesis de la información de cada uno de ellos y donde se incluyó: autor, año de publicación, diseño del estudio, objetivo, muestra, variables utilizadas, resultado y evaluación del riesgo de sesgos, para lo cual se utilizó la herramienta PROBAST, para evaluar

el riesgo de sesgos de los estudios primarios incluidos en esta revisión(37, 38). El riesgo de sesgos se clasificó en bajo, alto o poco claro, según el compromiso a la validez interna de los resultados producto de las deficiencias metodológicas encontradas en cada publicación. El análisis que se llevó a cabo sigue un orden secuencial por base de datos, sitio de búsqueda y tipo de estudio, con el fin de ayudar a la comprensión de los resultados individuales. Los siguientes fueron los resultados individuales de cada una de las publicaciones incluidas en esta revisión(37, 38).

Zhang et al(39) actualizaron la puntuación HOSPITAL simplificada(40), un modelo de predicción simple usado para identificar previo al alta de un paciente, el riesgo de reingreso a los 30 días potencialmente evitable, identificando aquellos pacientes que requieren intervenciones más intensivas en cuidados transicionales. Realizaron la inclusión de determinantes sociales a este modelo. Se usaron los registros electrónicos en salud de donde se extrajo la información respecto a diagnóstico, el procedimiento, las fechas de admisión/alta, estado del alta, la información socioeconómica individual. Su objetivo fue examinar el impacto de los determinantes sociales de la salud en los modelos predictivos para reingreso hospitalario temprano (30 días) potencialmente evitable, se incluyeron registros de egresos hospitalarios de 19941 pacientes, con reingreso a los 30 días o muerte (N = 3.019) y sin reingreso a los 30 días, ni muerte (N = 16.922). Este trabajo encontró que la inclusión de los determinantes sociales individuales o comunitarios, no mejoró significativamente la predicción de reingreso a los 30 días, aun cuando se encontró una mejora en el rendimiento del modelo, en pacientes según su tipo de aseguradora, edad igual o mayor a 65 años y en pacientes obesos. Este trabajo cuenta con algunas limitaciones como fueron el ser unicentrico, no se realizó un seguimiento individual a cada paciente luego del alta, solo se tuvieron en cuenta los registros institucionales de reingreso, es probable que algunos pacientes hayan reingresado en hospitales de la zona, que no sean el hospital índice, lo cual sería un sesgo de información, que comprometería la validez interna de este trabajo(39).



Belouali et al(31) evaluaron si agregar determinantes sociales al modelo predictivo LACE, que predice reingresos a los 30 días del alta hospitalaria, podría mejorar su rendimiento predictivo, resaltando la importancia de la predicción temprana y precisa, ya que los pacientes que tienen mayor riesgo de reingreso, son la clave para reducir costos hospitalarios para las aseguradoras en salud, lo que afectaría positivamente el sistema sanitario y facilitaría mejoras en los resultados en la salud de los pacientes. Se incluyeron en el estudio 316558 pacientes, 35431 (11,19%) pacientes reingresaron a los 30 días. El índice LACE es un modelo predictivo, validado que predice pacientes en riesgo de reingreso o muerte dentro de los 30 días posteriores al alta(41), este modelo incluye las siguientes variables: duración de la estancia ("L"); severidad al ingreso ("A"); comorbilidades del paciente (medida con la puntuación del índice de comorbilidad de Charlson) ("C"); y uso del servicio de urgencias (medido como el número de visitas en los seis meses anteriores al ingreso) ("E").

Los predictores para el estudio incluyeron el índice LACE y sus componentes, SDOH a nivel individual y SDOH a nivel comunitario. Incluyó los siguientes determinantes sociales en salud (sexo, raza, estado civil, acceso a la atención de salud, ropa, alimentación, alojamiento, estrés), concluyeron que los pacientes con reingresos no planificados a los 30 días tenían malas condiciones de sus determinantes individuales al compararlos con los pacientes sin reingresos. Se evidenciaron dificultades para acceder a la atención médica, pobre seguridad alimentaria, aumento en el número de circunstancias legales o encarcelamiento, mayor número de alteración en la seguridad física o emocional, aislamiento y falta de conexiones sociales y mayor estrés. Los pacientes con reingresos a los 30 días tenían mayor probabilidad de residir en comunidades con SDOH deficiente, eran principalmente fumadores, presentaron una mayor tasa de muertes por armas de fuego, un mayor consumo de alcohol, mayor tasa de hogares monoparentales, mayor número de crímenes violentos, mayor número de muertes por lesiones, mayor tasa de conducción solo al trabajo y menor (peor) índice de ambiente alimentario. Por otro lado, los pacientes no readmitidos tenían más

probabilidades de vivir en condados con un ingreso familiar promedio más alto, mayor porcentaje de adultos y niños sin seguridad social(31). La adición de SDOH a nivel comunitario al modelo base tuvo una mejoría pequeña pero significativa en su rendimiento con un AUC = 0,705 (IC 95 % [0,702–0,707]; $P < .001$) pero no tuvo un efecto en la puntuación de Brier (métrica utilizada para medir la precisión de los pronósticos probabilísticos). El modelo combinado con componentes LACE, SDOH a nivel individual y SDOH a nivel comunitario tuvo la mayor mejoría en comparación con el modelo base con un AUC igual a 0,708 (IC 95 % [0,705–0,71]; $P < .001$) y una puntuación mejorada de Brier igual a 0,09. Este estudio, concluyó que incluir SDOH en el modelo pronóstico, mejorar el índice LACE, diferentes subpoblaciones (negros y los pacientes de 65 años o más), se benefician más de la inclusión de SDOH en la predicción de readmisión(31).

Hall et al(42) exploraron la asociación de un conjunto integral de determinantes sociales en salud y la probabilidad de regresar al servicio de urgencias después del alta hospitalaria o del servicio de urgencias, incluyeron 123697 pacientes únicos, realizaron un proceso de imputación de datos faltantes para dar fuerza al modelo, se incluyeron los siguientes determinantes para el análisis: historial de abuso en el hogar, problemas en el hogar, educación, estado laboral, situación de vivienda, consumo de alcohol, consumo de tabaco, abuso de sustancias, restricción de alimentación y restricción de movimiento, dentro de sus hallazgos resalta el número de condiciones médicas como el predictor de mayor importancia relativa y es sustentado en el hecho de que personas más enfermas, tienen menor probabilidad de mantener estable su enfermedad, cabe resaltar múltiples deficiencias metodológicas, como son el alto número de datos faltantes que lleva a la necesidad de imputar(42). Concluye que los determinantes sociales como el acceso a una vivienda estable o un empleo remunerado tienen un profundo impacto en el bienestar de una persona. Este estudio no corresponde a la creación o validación de un modelo predictivo, es un estudio exploratorio donde se evidencia la relación entre algunas variables incluidas los SDOH(42).



Tabla 2. Características de los estudios revisados.

AUTOR/AÑO	DISEÑO DEL ESTUDIO	OBJETIVO	MUESTRA	VARIABLES UTILIZADAS	RESULTADO	RIESGO DE SESGOS
Zhang et al / 2020	Estudio de cohorte retrospectivo.	Examinar el impacto de los determinantes sociales de la salud en los modelos predictivos para reingreso hospitalario temprano (30 días) potencialmente evitable.	Registros de salud electrónicos para 19941 admisiones hospitalarias, con reingreso a los 30 días o muerte (N = 3.019) y sin reingreso a los 30 días, ni muerte (N = 16.922).	Frecuencia de los ingresos hospitalarios previos, la urgencia del ingreso, los últimos niveles disponibles de hemoglobina y sodio, el alta de una división de oncología y el índice de duración de la estancia hospitalaria, sexo, la raza, origen étnico, idioma principal, estado civil y tipo de seguro.	Este trabajo encontró que la inclusión de los determinantes sociales individuales o comunitariamente, no mejoró significativamente la predicción de reingreso a los 30 días, aun cuando se encontró una mejora en el rendimiento del modelo en pacientes según su tipo de aseguradora, edad igual o mayor a 65 años y pacientes obesos.	Alto
Beloualiet al / 2021	Estudio de cohorte retrospectivo.	Desarrollar una puntuación predictiva que mida la influencia de las características del paciente en las intervenciones del programa de telemedicina (MT).	Se estratificaron por tipo de enfermedad y se emparejaron por gravedad de la enfermedad en un grupo de intervención de MT (N = 7782) y una cohorte de control de "atención habitual" sin telemedicina (N = 7981)	Género, edad, origen étnico, tipo de servicio en telemedicina, aseguradora, enfermedad de base, centro de atención, abuso de sustancias, número de comorbilidades.	Incluir SDOH en el modelo pronostico, mejorar el índice LACE, diferentes subpoblaciones (negros y los pacientes de 65 años o más), se beneficien más de la inclusión de SDOH en la predicción de readmisión.	Bajo
Hall et al / 2021	Modelo matemático seires de tiempo.	Identificar los factores de riesgo específicos relacionados con el crecimiento de casos de COVID-19.	Crecimiento relativo futuro de casos normalizados a la población en los condados de Tennessee y Georgia desde julio de 2020 hasta enero de 2021.	Características demográficas.	Los determinantes sociales como el acceso a una vivienda estable o un empleo remunerado tienen un profundo impacto en el bienestar de una persona. Este estudio no corresponde a la creación o validación de un modelo predictivo, es un estudio exploratorio donde se evidencia la relación entre algunas variables incluidas los SDOH.	Bajo
Crump et al / 2022	Estudio de cohorte retrospectivo.	Evaluar si agregar determinantes al modelo predictivo LACE, que predice reingresos a los 30 días del alta hospitalaria, puede mejorar su rendimiento predictivo.	El estudio incluyó 316 558 pacientes de los cuales 35 432 (11,1946) pacientes reingreso a los 30 días.	Sexo, raza, estado civil, acceso a la atención de salud, ropa, alimentación, alojamiento, estrés.	Las características de los pacientes y sus determinantes sociales contribuyen a la creación de una puntuación confiable y válida, para mejorar la orientación respecto al tratamiento del paciente y la consistencia de los resultados del programa de telemedicina. El modelado predictivo facilita mejores prácticas de salud digital, facilitando la estratificación del riesgo individual, la planificación de la atención y la toma de decisiones respecto a los recursos que se utilizaran para cada caso individual, identificando los pacientes que necesitan terapias más intensivas o enfoques de tratamiento más adecuados.	Alto
Gray et al / 2022	Estudio observacional retrospectivo transversal.	Explorar la asociación de un conjunto integral de indicadores SDOH y la probabilidad de regresar al servicio de urgencias después del alta hospitalaria o del servicio de urgencias.	123697 pacientes únicos.	El historial de abuso en el hogar, los problemas en el hogar, la educación, el estado laboral, la situación de vivienda, el consumo de alcohol, el consumo de tabaco, el abuso de sustancias, la restricción de alimentación y la restricción de movimiento.	Múltiples medidas de determinantes sociales, están asociadas con la probabilidad de reingreso al hospital, pero no son el predictor más importante.	Bajo

Fuente: Elaboración propia.

El objetivo principal de este estudio realizado por Crump et al (32) fue crear una puntuación de Telemedicina ImPact (TIP) confiable y válida, teniendo en cuenta las características del paciente, lo que permitió la creación de diferentes modelos con la capacidad de predecir resultados en salud y los efectos del tratamiento, estos modelos predictivos incluyeron los siguientes desenlaces: hospitalización, reingresos hospitalarios, utilización total de servicios en salud y mortalidad. Se concluyó que las características de los pacientes y sus determinantes sociales contribuyen a la creación de una puntuación confiable y válida, para mejorar la orientación respecto al tratamiento del paciente y la consistencia de los resultados del programa de telemedicina. El modelado predictivo facilita mejores prácticas de salud digital, facilitando la estratificación del riesgo individual, la planificación de la atención y la toma de decisiones respecto a los recursos que se utilizaran para cada caso individual, identificando los pacientes que necesitan terapias más intensivas o enfoques de tratamiento más adecuados. Como limitación en este modelo, se encontró que las variables de los determinantes en salud fueron abordadas parcialmente y a que no se contó con un registro completo de las mismas (32).

Gray et al(13) este trabajo combinó estadísticas de COVID-19 disponibles públicamente con SDOH de la información de salud a nivel de condado. Se utilizaron modelos de aprendizaje automático para predecir el crecimiento de casos de COVID-19 y comprender los factores de riesgo sociales, físicos y ambientales que se asociaron con tasas más altas de infección por SARS-CoV2 en los condados de Tennessee y Georgia. La precisión del modelo se evaluó comparando los recuentos de casos previstos con los recuentos de casos positivos reales en cada condado. Los modelos predictivos alcanzaron una media r-cuadrado (R²) de 0,998 en ambos estados con una precisión superior al 90% para todos los puntos temporales examinados. Se identificaron los factores de riesgo específicos relacionados con el crecimiento de casos de COVID-19, en los estados de Tennessee, Shelby y Davidson, utilizaron una serie temporal para determinar qué características demográficas afectaban positivamente el aumento de casos en diferentes meses y en diferentes estados, encontrando una relación en el condado de Shelby con un aumento gradual en importancia en la demografía asiática, y en el condado de Tennessee se relacionó con blancos no hispanos, así como tendencias contrastantes en afroamericanos(13).



DISCUSIÓN

Esta revisión sistemática logró identificar en los diferentes estudios incluidos, que los determinantes sociales ayudan a mejorar el nivel de predicción y discriminación en los modelos, donde aun con leves mejoras en los valores de predicción, se encontró diferencias estadísticamente significativas(39), lo que estaría acorde con lo reportado por de Boer(15) quien llevó a cabo una revisión sistemática y efectuó un análisis multivariable y una regresión logística para definir que variables son predictoras del estado de salud de un individuo, encontró gran heterogeneidad entre los estudios evaluados, pero pudo describir como factores predisponentes edad, sexo, estado marital y nivel educativo, aun cuando en esta revisión estos factores no son categorizados como SDOH, se sabe que pertenecen a este grupo de determinantes, adicionalmente estos autores no encuentran efecto sobre la salud en vivir en el centro de la ciudad, sitio de residencia o distancia al hospital(15). Se evidenció que tiene un mayor rendimiento en los modelos predictivos la inclusión de SDOH individuales y comunitarios, que la inclusión individual de estos determinantes (31, 43). Por lo anterior se puede concluir que se incluyen los SDOH individuales y comunitarios en los modelos de predicción de enfermedad se podría disminuir las desigualdades sociales e identificar aquella población más susceptible y que requiere de mayor atención a la hora de recibir una atención en salud o de servicios ofertados en un programa comunitario orientado a la prevención primaria a largo plazo, dando fuerza a un sistema de salud y mejorando su economía, al direccionar de una manera más eficaz los recursos en salud (39, 44).

En la era de la innovación digital, cuando se están llevando a cabo estrategias a nivel global para mejorar el registro de información y poder facilitar el acceso a la misma(34, 45), surgen interrogantes al respecto como son, el cómo se podrá llevar a cabo un registro adecuado de información, garantizando la calidad del dato y la inclusión de variables tan importantes como los SDOH, en todas sus categorías y dominios, logrando obtener mayores cantidades de información y por este medio facilitar un escenario

propicio para los sistemas de salud, en cuanto a toma de decisiones y disposición de recursos(34, 44, 46, 47). Se consideran posible y necesaria la inclusión de este tipo de variables (SDOH) en los modelos de predicción aun cuando no se han variables clínicas, ya que aumentan la sensibilidad, especificidad y precisión de los modelos, las diferencias encontradas en el rendimiento de algunos modelos probablemente se deba a las características individuales de la población de estudio, que buscan atención medica dentro de sus áreas geográficas, este trabajo recomienda mejorar el emparejamiento de los pacientes con sus niveles de atención según sus condiciones médicas de salud, dirigiendo las políticas públicas a la prevención(16, 43, 46, 48, 49).

La historia clínica electrónica, es una herramienta útil para la recopilación de información respecto a los SDOH y en este momento en Colombia, cuando se está implementando la transformación digital en salud y donde la interoperabilidad de la historia clínica es pieza fundamental de este modelo, se considera la importancia de incluir los SDOH individuales y comunitarios para tener una visión más holística de la población Colombiana y poder desarrollar investigación que brinde resultados reales de dicha población y oriente las políticas públicas (20, 27, 49). En la actualidad se está procurando integrar estos SDOH a las Historias clínicas electrónicas, existen modelos que incluyen 11 dominios sociales y conductuales para llevar a cabo esta recolección de información(12, 16). Además, estos SDOH pueden usarse para la construcción de indicadores en salud que permitan realizar un seguimiento a metas sobre la salud y la calidad de vida de una población en especial, facilitando la disminución de brechas sociales y disminuyendo las inequidades que tienen como resultado desenlaces desfavorables en salud, esta es una perspectiva a futuro, tanto para la práctica clínica como para futuras investigaciones con el fin de dar fuerza a la investigación sobre los SDOH y su inclusión en este tipo de modelos buscando que los entes gubernamentales puedan generar políticas públicas basadas en información científica de calidad y que estas acciones logren impactar positivamente la morbilidad y mortalidad de nuestras poblaciones (12, 24, 29, 49-51).



Como limitaciones en el desarrollo de esta revisión sistemática se resalta la heterogeneidad de los estudios incluidos en la misma respecto a población y SDOH, las diferentes áreas geográficas de las personas incluidas, la baja calidad metodológica de algunos de los estudios pronósticos descritos y analizados, la imposibilidad que se tiene de generalizar resultados por la pobre validez interna de algunos estudios, pero se resalta el proceso crítico llevado a cabo en la bibliografía encontrada y la aplicación de herramientas metodológicas para el análisis de cada uno de los documentos aquí incluidos (15, 16, 23).

CONCLUSIÓN

Esta revisión sistemática permite concluir que los modelos predictivos que incluyen SDOH y herramientas digitales para recolección de información en salud, para predecir desenlaces en salud, mejoran sus valores predictivos y su precisión al incluir este tipo de variables, que los mejores resultados se obtienen con la inclusión de los SDOH individuales más los SDOH comunitarios. Los resultados de esta revisión respaldan la inclusión de los SDOH en los nuevos modelos de historia clínica electrónica que se están construyendo en Colombia como respuesta al proceso de implementación de la interoperabilidad de la historia clínica en el territorio nacional. Finalmente, se necesitan más estudios para mejorar la potencia y lograr disminuir la variabilidad de los estudios y poder medir el impacto de los SDOH en los resultados en salud.

REFERENCIAS

1. Croft P, Altman DG, Deeks JJ, Dunn KM, Hay AD, Hemingway H, et al. The science of clinical practice: disease diagnosis or patient prognosis? Evidence about "what is likely to happen" should shape clinical practice. BMC medicine. 2015;13:20.
2. Ohno-Machado L. Using health information technology for clinical decision support and predictive analytics. Journal of the American Medical Informatics Association : JAMIA. 2017;24(1):1.
3. Fletcher RH. Clinical medicine meets modern epidemiology--and both profit. Annals of epidemiology. 1992;2(3):325-33.
4. Breslow NE. Cohort Analysis in Epidemiology. In: Atkinson, AC, Fienberg, SE (eds) A Celebration of Statistics Springer, New York, NY 1985.
5. Tripepi G, Jager KJ, Dekker FW, Zoccali C. Testing for causality and prognosis: etiological and prognostic models. Kidney international. 2008;74(12):1512-5.
6. Hemingway H, Croft P, Perel P, Hayden JA, Abrams K, Timmis A, et al. Prognosis research strategy (PROGRESS) 1: a framework for researching clinical outcomes. Bmj. 2013;346:e5595.
7. Rothman KJ, Greenland S. Causation and causal inference in epidemiology. American journal of public health. 2005;95 Suppl 1:S144-50.
8. Sandra Isaza-Jaramillo FJ-B. Clinical and epidemiological round: Approach to clinical prediction models. Iatreia. 2016;2017 Ene-Mar;30(1):92-99.
9. Rothman KJ. The origin of Modern Epidemiology, the book. European journal of epidemiology. 2021;36(8):763-5.
10. Monge S, Diez M, Pulido F, Iribarren JA, Campins AA, Arazo P, et al. Tuberculosis in a cohort of HIV-positive patients: epidemiology, clinical practice and treatment outcomes. The international journal of tuberculosis and lung disease : the official journal of the International Union against Tuberculosis and Lung Disease. 2014;18(6):700-8.
11. Kent P, Cancelliere C, Boyle E, Cassidy JD, Kongsted A. A conceptual framework for prognostic research. BMC medical research methodology. 2020;20(1):172.
12. Moons KG, Altman DG, Vergouwe Y, Royston P. Prognosis and prognostic research: application and impact of prognostic models in clinical practice. Bmj. 2009;338:b606.
13. Gray JD, Harris CR, Wylezinski LS, Spurlock CF, 3rd. Predictive Modeling of COVID-19 Case Growth Highlights Evolving Demographic Risk Factors in Tennessee and Georgia. medRxiv : the preprint server for health sciences. 2021.



14. Marmot M, Friel S, Bell R, Houweling TA, Taylor S, Commission on Social Determinants of H. Closing the gap in a generation: health equity through action on the social determinants of health. *Lancet*. 2008;372(9650):1661-9. 15.
15. de Boer AG, Wijker W, de Haes HC. Predictors of health care utilization in the chronically ill: a review of the literature. *Health policy*. 1997;42(2):101-15.
16. Lipshutz JA, Hall JE, Penman-Aguilar A, Skillen E, Naom S, Irune I. Leveraging Social and Structural Determinants of Health at the Centers for Disease Control and Prevention: A Systems-Level Opportunity to Improve Public Health. *Journal of public health management and practice : JPHMP*. 2022;28(2):E380-E9.
17. +Crear-Perry J, Correa-de-Araujo R, Lewis Johnson T, McLemore MR, Neilson E, Wallace M. Social and Structural Determinants of Health Inequities in Maternal Health. *Journal of women's health*. 2021;30(2):230-5.
18. Hacker K, Houry D. Social Needs and Social Determinants: The Role of the Centers for Disease Control and Prevention and Public Health. *Public health reports*. 2022;137(6):1049-52.
19. Cantor MN, Thorpe L. Integrating Data On Social Determinants Of Health Into Electronic Health Records. *Health affairs*. 2018;37(4):585-90.
20. Chen M, Tan X, Padman R. Social determinants of health in electronic health records and their impact on analysis and risk prediction: A systematic review. *Journal of the American Medical Informatics Association : JAMIA*. 2020;27(11):1764-73.
21. Spruce L. Back to Basics: Social Determinants of Health. *AORN journal*. 2019;110(1):60-9.
22. Jilani MH, Javed Z, Yahya T, Valero-Elizondo J, Khan SU, Kash B, et al. Social Determinants of Health and Cardiovascular Disease: Current State and Future Directions Towards Healthcare Equity. *Current atherosclerosis reports*. 2021;23(9):55.
23. Tso P, Culyer AJ, Brouwers M, Dobrow MJ. Developing a decision aid to guide public sector health policy decisions: a study protocol. *Implementation science : IS*. 2011;6:46.
24. Penman-Aguilar A, Talih M, Huang D, Moonesinghe R, Bouye K, Beckles G. Measurement of Health Disparities, Health Inequities, and Social Determinants of Health to Support the Advancement of Health Equity. *Journal of public health management and practice : JPHMP*. 2016;22 Suppl 1(Suppl 1):S33-42.
25. Penman-Aguilar A, Talih M, Moonesinghe R, Huang D. Response to Scanlan Concerning: Measurement of Health Disparities, Health Inequities, and Social Determinants of Health to Support the Advancement of Health Equity. *Journal of public health management and practice : JPHMP*. 2016;22(6):614-5.
26. Nanda P. Information Processing and Data Analytics for Decision Making: A Journey From Traditional to Modern Approaches. *Information Resources Management Journal*. 2022;Volume 35 (Issue 2).
27. Saiso SG, Marti MC, Medina FM, Pascha VM, Nelson J, Tejerina L, et al. Digital Transformation for More Equitable and Sustainable Public Health in the Age of Digital Interdependence. *American journal of public health*. 2022;112(S6):S621-S4.
28. Garcia Saiso S, Marti MC, Mejia Medina F, Pascha VM, Nelson J, Tejerina L, et al. [Digital transformation for more equitable and sustainable public health in the age of digital interdependence Transformacao digital para uma saude publica mais equitativa e sustentavel na era da interdependencia digital]. *Revista panamericana de salud publica = Pan American journal of public health*. 2022;46:e1.
29. Hatef E, Weiner JP, Kharrazi H. A public health perspective on using electronic health records to address social determinants of health: The potential for a national system of local community health records in the United States. *International journal of medical informatics*. 2019;124:86-9.
30. (WHO) WHO. Declaração política do Rio sobre determinantes sociais da saúde. http://www.who.int/sdhconference/declaration/.Rio_political_declaration_portuguese.pdf (accessed on 23/Jan/2016). 2016.



31. Belouali A, Bai H, Raja K, Liu S, Ding X, Kharrazi H. Impact of social determinants of health on improving the LACE index for 30-day unplanned readmission prediction. *JAMIA open*. 2022;5(2):ooac046.
32. Crump CA, Wernz C, Schlachta-Fairchild L, Steidle E, Duncan A, Cathers L. Closing the Digital Health Evidence Gap: Development of a Predictive Score to Maximize Patient Outcomes. *Telemedicine journal and e-health : the official journal of the American Telemedicine Association*. 2021;27(9):1029-38.
33. E. DJLADÁ. Digital Transformation of the Healthcare System for the incorporation of Personalized Precision Medicine. 2022.
34. Kasthurirathne SN, Vest JR, Menachemi N, Halverson PK, Grannis SJ. Assessing the capacity of social determinants of health data to augment predictive models identifying patients in need of wraparound social services. *Journal of the American Medical Informatics Association : JAMIA*. 2018;25(1):47-53.
35. PAHO. Pan American Health Organization. Information systems for health: definition of guiding principles (is4h). descriptive note 01. 2018.
36. Moher D, Liberati A, Tetzlaff J, Altman DG, Group P. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS medicine*. 2009;6(7):e1000097.
37. Wolff RF, Moons KGM, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies. *Annals of internal medicine*. 2019;170(1):51-8.
38. Moons KGM, Wolff RF, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess Risk of Bias and Applicability of Prediction Model Studies: Explanation and Elaboration. *Annals of internal medicine*. 2019;170(1):W1-W33.
39. Zhang Y, Zhang Y, Sholle E, Abedian S, Sharko M, Turchioe MR, et al. Assessing the impact of social determinants of health on predictive models for potentially avoidable 30-day readmission or death. *PloS one*. 2020;15(6):e0235064.
40. Donze J, Aujesky D, Williams D, Schnipper JL. Potentially avoidable 30-day hospital readmissions in medical patients: derivation and validation of a prediction model. *JAMA internal medicine*. 2013;173(8):632-8.
41. van Walraven C, Dhalla IA, Bell C, Etchells E, Stiell IG, Zarnke K, et al. Derivation and validation of an index to predict early death or unplanned readmission after discharge from hospital to the community. *CMAJ : Canadian Medical Association journal = journal de l'Association medicale canadienne*. 2010;182(6):551-7.
42. Hall AG, Davlyatov GK, Orewa GN, Mehta TS, Feldman SS. Multiple Electronic Health Record-Based Measures of Social Determinants of Health to Predict Return to the Emergency Department Following Discharge. *Population health management*. 2022.
43. Bolster-Foucault C, Ho Mi Fane B, Blair A. Structural determinants of stigma across health and social conditions: a rapid review and conceptual framework to guide future research and intervention. *Health promotion and chronic disease prevention in Canada : research, policy and practice*. 2021;41(3):85-115.
44. Powell-Wiley TM, Baumer Y, Baah FO, Baez AS, Farmer N, Mahlobo CT, et al. Social Determinants of Cardiovascular Disease. *Circulation research*. 2022;130(5):782-99.
45. Garg A, Homer CJ, Dworkin PH. Addressing Social Determinants of Health: Challenges and Opportunities in a Value-Based Model. *Pediatrics*. 2019;143(4).
46. Kuijpers T, van der Windt D, Boeke JPA, Twisk JWR, Vergouwe Y, Bouter LM, et al. Clinical prediction rules for the prognosis of shoulder pain in general practice. *Pain*. 2006;120(3):276-85.
47. Mannoh I, Hussien M, Commodore-Mensah Y, Michos ED. Impact of social determinants of health on cardiovascular disease prevention. *Current opinion in cardiology*. 2021;36(5):572-9.
48. Stanhope V, Videka L, Thorning H, McKay M. Moving toward integrated health: an opportunity for social work. *Social work in health care*. 2015;54(5):383-407.
49. Loeb DF, Binswanger IA, Candrian C, Bayliss EA. Primary care physician insights into a typology of



50. Murray TA. Teaching the Social and Structural Determinants of Health: Considerations for Faculty. *The Journal of nursing education*. 2021;60(2):63-4.
51. Cogburn CD. Culture, Race, and Health: Implications for Racial Inequities and Population Health. *The Milbank quarterly*. 2019;97(3):736-61.