

<b>Título</b>	Resumen de evidencia: Uso de sistemas de puntuación clínica para el diagnóstico y tratamiento del COVID-19
<b>Código de Identificación</b>	07032020IH
<b>Área Solicitante</b>	COVID-191. Comité de Crisis en Salud Pública Keralty
<b>Nombre</b>	COVID-191. Comité de Crisis en Salud Pública Keralty
<b>Fecha de Respuesta</b>	03 07 2020

**Pregunta:**

¿Cuál es la evidencia sobre el uso de sistemas de puntuación clínica para el diagnóstico y tratamiento del COVID-19?

**Metodología:**

Se realizó una Revisión Sistemática Rápida (Manual de Revisiones Sistemáticas Rápidas. Instituto Global de Excelencia Clínica. 2019)

**Términos de Búsqueda:** COVID 19, Coronavirus, SARS-CoV-2,

**Tipos de estudio:** Recomendaciones de sociedades científicas, agencias regulatorias y organismos referentes en salud nacionales e internacionales, revisiones sistemáticas de la literatura (RSL), meta análisis, ensayos clínicos y otros estudios primarios.

**Fuentes de Información:** Pubmed, Google Scholar.

**Antecedentes:**

La necesidad de instaurar medidas preventivas con prontitud ha llevado a algunos organismos de salud a recomendar dar diagnósticos de COVID-19 basados en los síntomas y revisión clínica de pacientes. Así por ejemplo, La Red de Alerta de Salud del Departamento de Salud y Servicios Humanos de Nebraska afirma que, "dadas las consecuencias de la transmisión generalizada", las autoridades de salud pública han determinado que un diagnóstico clínico de COVID-19 es suficiente para garantizar el auto-aislamiento, sin necesidad de pruebas. Los siguientes síntomas son suficientes para justificar el autoaislamiento: Fiebre, Tos, La falta de aliento, Dolor de garganta. En adelante, si alguno de estos síntomas está presente, se pedirá a los pacientes que se auto-aíslen sin una prueba positiva. (Nebraska Health, 2020).

Adicionalmente de acuerdo con una revisión Cochrane en relación a las pruebas para COVID-19 "en una población en la que COVID-19 era más común habría más falsos negativos y menos falsos positivos." (Deeks et al., 2020).

En una revisión sistemática de la literatura y metanálisis sobre los factores de riesgo en casos críticos y mortales realizada por Zhen et al. (2020) se encontró que "Los hombres, de más de 65 años, que fuman pueden correr un mayor riesgo de desarrollar una condición crítica o mortal y las comorbilidades como la hipertensión, la diabetes, las enfermedades cardiovasculares y las enfermedades respiratorias también pueden afectar en gran medida el pronóstico de la COVID-19. Las manifestaciones clínicas como la fiebre, la falta de aliento o la disnea y los exámenes de laboratorio como el WBC, AST, Cr, PCT, LDH, hs-cTnI y el dímero D podrían implicar la progresión de COVID-19." (Zhen et al., 2020)

Dado que continúa aumentando el número de casos, las pruebas existentes no son de resultados inmediatos y pueden llegar a escasear además de tener falsos negativos, la existencia de datos

epidemiológicos y clínicos, usar una herramienta de predicción basada en hallazgos clínicos y demográficos parece un camino razonable dirigido a garantizar una mejor calidad de la atención.

### **Descripción de la tecnología**

Los sistemas de puntuación para apoyar la toma de decisiones clínicas pueden ser computarizados o en papel. Para una lectura más completa sobre ventajas de unos y otros se recomienda Kawamoto et al (2005). La tendencia en el 2020 es usar sistemas de puntuación computarizados por la facilidad de registro, manejo y seguimiento.

Medic et al (2019) señalan que “Los sistemas de apoyo a la decisión computarizada (CDS) han surgido como herramientas que proporcionan una toma de decisiones inteligente basada en los datos del paciente para abordar muchos de los retos de los cuidados críticos. Los sistemas de CDS pueden basarse en las directrices existentes o en las mejores prácticas; y también pueden utilizar el aprendizaje por máquina como medio de recopilar varios datos para proporcionar un diagnóstico, una recomendación o un curso de terapia” (Medic et al., 2019).

Birkner et al (2007) señalaron que “el problema general de la creación de puntuaciones de diagnóstico para la predicción de los resultados clínicos puede dividirse en dos partes: 1) la elección del conjunto de variables más relevantes desde el punto de vista médico en relación con el resultado de interés (pericia clínica) y 2) la combinación de estas variables en una forma funcional (modelo) que proporcione la predicción futura más precisa del resultado (pericia estadística)” (Birkner et al., 2007)

El impacto en el estados de salud de las personas de los sistemas de apoyo (DSS) a la decisión clínica aún no tiene evidencia de calidad suficiente, las revisiones sistemáticas que encontramos demuestran mejoras en flujos de trabajo y tiempo (Patel et al., 2019), pero no necesariamente mejoría clínica.

Los sistemas de alerta temprana (EWS) son sistemas de CDS diseñados para la evaluación inicial y la identificación de pacientes en riesgo de deterioro en las áreas de las salas de hospitalización (Medic et al., 2019).

### **Hallazgos / Respuesta a Interrogante**

A la pregunta .¿ ¿Cuál es la evidencia sobre el uso de sistemas de puntuación clínica para el diagnóstico y tratamiento del COVID-19? Sí se encontró evidencia de uso de sistemas de puntuación clínica: 1 revisión sistemática de abril de 2020 actualizada el 3 de junio de 2020, 1 metanálisis publicado el 27 de junio de 2020, una revisión pragmática no sistemática del 22 de abril de 2020 y tres estudios de cohorte publicados uno el 19 de mayo, otro el 8 de junio y el último el 1 de julio de 2020.

Wynant et al. (2020) hicieron una revisión sistemática y evaluación crítica en vivo y concluyeron que ninguno de los modelos reportados era recomendable dado el alto nivel de sesgo y falta de información detectada, Ver tabla 1. De acuerdo con Wynant et al. revisaron “4909 títulos y se incluyeron 51 estudios que describían 66 modelos de predicción. El examen identificó tres modelos para predecir el ingreso hospitalario por neumonía y otros eventos (como resultados aproximados de la neumonía covid-19) en la población general; 47 modelos de diagnóstico para detectar la covid-19 (34 se basaron en imágenes médicas); y 16 modelos de pronóstico para predecir el riesgo de mortalidad, la progresión a una enfermedad grave o la duración de la estancia hospitalaria. Los factores de predicción de la presencia de covid-19 que se comunicaron con mayor frecuencia fueron la edad, la temperatura corporal, los signos y síntomas, el sexo, la presión arterial y la creatinina. Los factores de predicción más frecuentes del pronóstico grave en los pacientes con covid-19 incluían la edad y las características derivadas de las tomografías computarizadas. Las estimaciones del índice C oscilaban entre 0,73 y 0,81 en los

modelos de predicción para la población general, entre 0,65 y más de 0,99 en los modelos de diagnóstico y entre 0,85 y 0,99 en los modelos de pronóstico. Todos los modelos se calificaron con un riesgo de sesgo alto o poco claro, debido principalmente a la selección no representativa de los pacientes de control, la exclusión de los pacientes que no habían experimentado el evento de interés al final del estudio, el alto riesgo de que el modelo se sobreajustara y la vaguedad de la información. La mayoría de los informes no incluían ninguna descripción de la población de estudio ni del uso previsto de los modelos, y rara vez se evaluaba la calibración de las predicciones de los modelos.” (Wynant et al. 2020). Finaliza Wynant et al. concluyendo que “Los modelos de predicción para el covid-19 están entrando rápidamente en la literatura académica para apoyar la toma de decisiones médicas en un momento en que se necesitan con urgencia. Esta revisión indica que los modelos propuestos están mal informados, con un alto riesgo de sesgo, y que su rendimiento informado es probablemente optimista. Por lo tanto, no recomendamos ninguno de estos modelos de predicción reportados para ser usados en la práctica actual. Se necesita urgentemente compartir de inmediato los datos bien documentados de los participantes individuales de los estudios del covid-19 y colaborar para desarrollar modelos de predicción más rigurosos y validar los que sean prometedores. Los pronosticadores identificados en los modelos incluidos deben considerarse como pronosticadores candidatos para los nuevos modelos. Se debe seguir la orientación metodológica porque las predicciones poco fiables podrían causar más daño que beneficio al orientar las decisiones clínicas. Por último, los estudios deben adherirse a la directriz de presentación de informes del TRIPOD (informe transparente de un modelo de predicción multivariable para el pronóstico o el diagnóstico individual).” (Wynant et al. 2020).

**Tabla 1. Riesgo de sesgo por participantes, predictores, resultados y análisis de estudios de modelos de predicción, Revisión hecha por Wynant et al. (2020).**

Autores de estudios de modelos de predicción en COVID-19	Riesgo de sesgo			
	Participantes	Predictores	Resultados	Análisis
<b>Admisión en hospitales población general</b>				
DeCaprio et al	Alto	Bajo	Alto	Alto
<b>Diagnostico Clínico</b>				
Feng et al	Bajo	No claro	Alto	Alto
Lopez-Rincon et al	No claro	Bajo	Bajo	Alto
Meng et al	Alto	Bajo	Alto	Alto
Song et al	Alto	No claro	Bajo	Alto
Yu et al	No claro	No claro	No claro	Alto
Martin et al	Alto	Alto	Alto	Alto
Sun et al	Bajo	Bajo	No claro	Alto
Wang et al	Bajo	No claro	No claro	Alto
Wu et al	Alto	No claro	Bajo	Alto
Zhou et al	No claro	Bajo	Alto	Alto
<b>Imágenes Diagnósticas</b>				
Barstugan et al	No claro	No claro	No claro	Alto
Chen et al	Alto	No claro	Bajo	Alto*
Gozes et al	No claro	No claro	Alto	Alto
Jin et al	Alto	No claro	No claro	Alto†
Jin et al	Alto	No claro	Alto	Alto*
Li et al	Bajo	No claro	Bajo	Alto
Shan et al	No claro	No claro	Alto	Alto†
Shi et al	Alto	No claro	Bajo	Alto
Wang et al	Alto	No claro	Bajo	Alto
Xu et al	Alto	No claro	Alto	Alto
Song et al	No claro	No claro	Bajo	Alto
Zheng et al	No claro	No claro	Alto	Alto
Abbas et al	Alto	No claro	No claro	Alto
Apostolopoulos et al	Alto	No claro	Alto	Alto
Bukhari et al	No claro	No claro	No claro	Alto

Chaganti et al	Alto	No claro	Bajo	No claro
Chowdhury et al	Alto	No claro	No claro	Alto
Fu et al	Alto	No claro	No claro	Alto
Gozes et al	Alto	No claro	No claro	Alto
Imran et al	Alto	No claro	No claro	Alto*
Li et al	Bajo	Bajo	No claro	Alto
Li et al	Alto	No claro	Alto	Alto*
Hassanien et al	No claro	No claro	No claro	Alto*
Tang et al	No claro	No claro	Alto	Alto
Wang et al	Bajo	No claro	No claro	Alto
Zhang et al	Alto	No claro	Alto	Alto
Zhou et al	Alto	No claro	Alto	Alto*
<b>Pronóstico</b>				
Bai et al	Bajo	No claro	No claro	Alto
Caramelo et al	Alto	Alto	Alto	Alto
Gong et al	Bajo	No claro	No claro	Alto
Lu et al	Bajo	Bajo	Bajo	Alto
Qi et al	No claro	Bajo	Bajo	Alto
Shi et al	Alto	Alto	Alto	Alto
Xie et al	Bajo	Bajo	Bajo	Alto
Yan et al	Bajo	Alto	Bajo	Alto
Yuan et al	Bajo	Alto	Bajo	Alto
Huang et al	No claro	No claro	No claro	Alto
Pourhomayoun et al	Bajo	Bajo	No claro	Alto
Sarkar et al	Alto	Alto	Alto	Alto
Wang et al	Bajo	Bajo	Bajo	Alto
Zeng et al	Bajo	Bajo	Bajo	Alto

Fuente: Wynant et al. (2020).

En un metanálisis de Altmayer et al. (2020), publicado el 27 de junio de 2020, cuyo objetivo era comparar los resultados de la tomografía computarizada de tórax (TC) de la enfermedad coronavirus 2019 (COVID-19) con otra neumonía viral no causada por el virus COVID, en los que consideraron únicamente estudios con más de 10 participantes, concluyo que las TC son muy parecidas a las de otras neumonías virales y la diferencia radica en en mayor prevalencia de distribución periférica y afectación de lóbulos superior y medio, describen su metanálisis así: “de los 2263 estudios identificados, 33 fueron elegibles para su inclusión, con un total de 1911 pacientes (COVID-19, n = 934; no COVID, n = 977). Las características frecuentes de la TC tanto para la neumonía viral COVID-19 como para la no COVID fueron un patrón mixto de opacidad de vidrio esmerilado (GGO) y consolidación (COVID-19, 0,37; 0,17-0,56; no COVID, 0,46; 0,35-0,58) o un patrón predominantemente GGO (COVID-19, 0,42; 0,28-0,55; no COVID 0,25; 0,17-0,32), distribución bilateral (COVID-19, 0,81; 0,77-0,85; no COVID, 0,69; 0,54-0,84), y afectación de los lóbulos inferiores (COVID-19, 0,88; 0,80-0,95; no COVID, 0,61; 0,50-0,82). La neumonía por COVID-19 presentaba una mayor prevalencia de distribución periférica (COVID-19 0,77; 0,67-0,87; no COVID 0,34; 0,18-0,49), y afectación de los lóbulos superior (COVID-19, 0,77; 0,65-0,88; no COVID 0,18; 0,10-0,27) y medio (COVID-19, 0,61; 0,47-0,76; no COVID 0,24; 0,11-0,38).” (Altmayer et al., 2020)

**Tabla 2. Características de estudios de neumonía COVID-19 y de otros tipos por Altmayer**

Estudio	Patógeno	Tamaño de la muestra	Masculino, no. (%)	Edad, media, (Desviación estándar) [IQR], años
Bai et al (2020), China	COVID-19	219	119 (54.3)	44.8 (14.5)
Bernheim et al (2020), China	COVID-19	121	61 (50.4)	45.3 (16)
Caruso et al (2020), Italy	COVID-19	158	83 (52.4)	57 [18–80]
Inui et al (2020), Japan	COVID-19	112	59 (52.7)	60 (17)
Li et al (2020), China	COVID-19	51	28 (54.9)	58 [26–83]
Liu et al (2020), China	COVID-19	73	41 (56.2)	41.6 (14.5)
Ng et al (2020), China	COVID-19	20	13 (61.9)	56 [37–65]
Pan et al (2020), China	COVID-19	63	33 (52.4)	44.9 (15.2)
Shi et al (2020), China	COVID-19	66	35 (53.0)	49.5 (11)
Song et al (2020), China	COVID-19	51	25 (49.0)	49 (16)
Amorim et al (2013), Brazil	H1N1	71	33 (46.5)	41.3 [16–92]
Cho et al (2011), South Korea	H1N1	37	21 (56.8)	46.1 (17.3)
Grieser et al (2012), Germany	H1N1	23	16 (69.6)	42.2 (16)
Henzler et al (2010), Germany	H1N1	10	6 (60.0)	45.3 [27–65]
Hwang et al (2013), South Korea	AdV	11	11 (100)	NA
Kang et al (2012), South Korea	H1N1	76	42 (55.3)	52 [18–86]
Karadeli et al (2011), Turkey	H1N1	52	21 (40.4)	41 (1.3)
Kim et al (2011), South Korea	H1N1	11	NA	30.7 [18–79]
Ishiguro et al (2016), Japan	H1N1	20	16 (80.0)	59.9 (16.4)
Lee et al (2012), South Korea	H1N1	45	45 (100)	20 [19–24]
Li et al (2011), China	H1N1	106	54 (50.9)	31.7 (15.7)
Li et al (2011), China	H1N1	26	16 (61.5)	53 [40–62]
Marchiori et al (2010), Brazil	H1N1	20	11 (55.0)	42.7 [24–62]
Nicolini et al (2012), Italy	H1N1	28	15 (53.6)	31.7 [26–78]
Park et al (2016), South Korea	AdV	104	98 (94.2)	20.1 [19–24]
Qi et al (2014), China	H1N1	16	0	27 [22–41]
Shiley et al (2010), USA	H1N1, AdV, RSV, PIV	18	5 (27.8)	55
Sohn et al (2013), South Korea	H1N1	41	21 (51.2)	46 [24–63]
Son et al (2011), South Korea	H1N1	20	13 (65.0)	46.5 [18–69]
Song et al (2011), South Korea	H1N1	30	6 (20.0)	36.6 (16.3)
Tanaka et al (2011), Japan	H1N1	10	6 (60.0)	61.3 [26–85]
Valente et al (2011), Italy	H1N1	50	NA	40.9 [21–76]
Yoon et al (2017), South Korea	AdV	152	152 (100)	21 (2.1)

Fuente: Altmayer et al. (2020)

El centro de evaluación de evidencia (CEBM) de la Universidad Oxford publica en su página web una revisión pragmática no sistemática del 22 de abril de 2020 que retoma varios de los estudios revisados por Wynant et al. (2020) y concluye que ninguno de estos sistemas es lo suficientemente robusto para recomendarlo. Ver tabla 3.

**Tabla 3. Revisión de sistemas de puntuación del CEBM de Oxford.**

Sistema de Puntuación (Score)	COVID-19 datos*	Propósito	Tamaño de la muestra**	Validado
<a href="#">Coronavirus Mortality Risk Calculator4</a>	No	Riesgo de Mortalidad	50,31	No
<a href="#">COVID-19 Prognostic Tool5</a>	Sí	Riesgo de Mortalidad	China: 44,672; USA: 4,226	No
<a href="#">COVID-19 Vulnerability Index6</a>	No	Riesgo de complicaciones	1,481,654	No
<a href="#">Shi et al. (2020) Risk Score7</a>	Sí	Riesgo de Severidad	487	Sí
<a href="#">Surgisphere Mortality Risk Calculator8</a>	Sí	Riesgo de Mortalidad	4,296	No
<a href="#">Surgisphere Severity Scoring Tool9</a>	Sí	Riesgo de Severidad	13,5	No
<a href="#">Surgisphere Triage Decision Support Tool10</a>	Sí	Recomendaciones de Triage	>10,000	No

\*Si la puntuación fue desarrollada usando datos de personas con COVID-19

\*\*El tamaño total de la muestra utilizada en el desarrollo de la puntuación, excluyendo las pruebas o la validación

El estudio de Mei et al (2020) publicado el 19 de mayo de 2020 en Nature arroja luces del uso de inteligencia artificial en el diagnóstico de COVID-19 sin usar pruebas diagnósticas de laboratorio “Para el diagnóstico de la enfermedad coronavirus 2019 (COVID-19), se utiliza rutinariamente una prueba de reacción en cadena de la polimerasa de transcriptasa inversa (RT-PCR) específica del virus SARS-CoV-2. Sin embargo, esta prueba puede tardar hasta 2 d en completarse, puede ser necesario realizar pruebas en serie para descartar la posibilidad de obtener resultados negativos falsos y actualmente hay escasez de kits de prueba RT-PCR, lo que subraya la urgente necesidad de métodos alternativos para el diagnóstico rápido y preciso de los pacientes con COVID-19. La tomografía computarizada (TC) de tórax es un componente valioso en la evaluación de los pacientes con sospecha de infección por SARS-CoV-2. No obstante, la TC por sí sola puede tener un valor predictivo negativo limitado para descartar la infección por SARS-CoV-2, ya que algunos pacientes pueden presentar hallazgos radiológicos normales en las primeras etapas de la enfermedad. En este estudio, utilizamos algoritmos de inteligencia artificial (IA) para integrar los hallazgos de la TC de tórax con los síntomas clínicos, el historial de exposición y las pruebas de laboratorio para diagnosticar rápidamente a los pacientes que son positivos para el COVID-19. De un total de 905 pacientes sometidos a pruebas por ensayo de RT-PCR en tiempo real y RT-PCR de secuenciación de última generación, 419 (46,3%) resultaron positivos para el SARS-CoV-2. En un conjunto de pruebas de 279 pacientes, el sistema de IA alcanzó un área bajo la curva de 0,92 y tuvo igual sensibilidad en comparación con un radiólogo torácico superior. El sistema de IA también mejoró la detección de los pacientes que dieron positivo en la prueba de COVID-19 mediante RT-PCR que se presentaron con tomografías computarizadas normales, identificando correctamente a 17 de 25 (68%) pacientes, mientras que los radiólogos clasificaron a todos estos pacientes como COVID-19 negativos. Cuando se dispone de las tomografías computarizadas y la

historia clínica asociada, el sistema de IA propuesto puede ayudar a diagnosticar rápidamente a los pacientes con COVID-19.” (Mei et al., 2020).

Huang et al. (2020) publicaron un estudio retrospectivo, multicéntrico y observacional para determinar si una puntuación de riesgo para el diagnóstico de COVID-19 era útil en pacientes sospechosos., encontraron 9 factores de riesgo independientes. Ver tabla 4. Este es un estudio con alto nivel de riesgo en la selección de participantes, también los tratamientos utilizados han podido alterar los resultados. De acuerdo con Huang et al. “se analizaron los datos clínicos de todos los pacientes sospechosos. Se identificaron factores de riesgo independientes mediante un análisis de regresión logística multivariante. Finalmente, se incluyeron 336 pacientes confirmados con COVID-19 y 139 pacientes de control. Se encontraron nueve factores de riesgo independientes para el diagnóstico de COVID-19 en el momento del ingreso en el hospital: antecedentes de exposición epidemiológica (OR:13,32; IC 95%, 6,39-27,75), debilidad/fatiga (OR:4,51; IC 95%, 1,70-11,96), frecuencia cardíaca inferior a 100 latidos/minuto (OR:3,80; IC 95%, 2,00-7,22), neumonía bilateral (OR:3,60; IC 95%, 1,83-7,10), recuento de neutrófilos menor que igual a  $6,3 \times 10^9 /L$  (OR: 6,77, IC 95%, 2,52-18,19), recuento de eosinófilos menor que igual a  $0,02 \times 10^9 /L$  (OR:3,14, IC 95%, 1,58-6,22), glucosa más que igual a 6 mmol/L (OR:2.43, 95%CI, 1.04-5.66), dímero D  $\geq 0.5$  mg/L (OR:3.49, 95%CI, 1.22-9.96), y proteína C reactiva menos de 5 mg/L (OR:3.83, 95%CI, 1.86-7.92). En cuanto al desempeño de esta puntuación de riesgo, se identificó un valor de corte de 20 (especificidad: 0,866; sensibilidad: 0,813) para predecir la COVID-19 de acuerdo con la curva característica del operador receptor y el área bajo la curva fue de 0,921 (IC del 95%: 0,896-0,945;  $P < 0,01$ ). Diseñamos una nueva puntuación de riesgo que podría tener una capacidad predictiva prometedora para el diagnóstico de COVID-19 entre los pacientes sospechosos” (Huang et al., 2020).

**Tabla 4. Factores de riesgo para pacientes sospechosos de COVID-19 por Huang et al. (2020)**

Factores de Riesgo independientes	Puntuación
Historias de exposición epidemiológica	13
Recuento de neutrófilos $\times 10^9/L$ , $\leq 6.3$	7
Debilidad/fatiga	5
Neumonía bilateral	4
Ritmo cardíaco (latidos/min), $<100$	4
Proteína C-reactiva, mg/L, $<5$	4
Recuento de eosinófilos $\times 10^9/L$ , $\leq 0.02$	3
Dímero D, mg/L, $\geq 0.5$	3
Glucosa, mmol/L, $\geq 6$	2

Fuente: tomado de Huang et al. (2020).

Qin et al. (2020) publicaron un estudio de cohorte el 1 de julio de 2020 cuyo objetivo era desarrollar un modelo predictivo y un sistema de puntuación para mejorar la eficiencia del diagnóstico del COVID-19 encontrando desde su evaluación como apropiado para el diagnóstico provisional antes de recibir los resultados de PCR y lo reportan así “del 19 de enero al 6 de febrero de 2020, se inscribieron retrospectivamente 88 pacientes con COVID-19 confirmados que presentaban neumonía y 80 pacientes sin COVID-19 que sufrían de neumonía de otros orígenes. Se recogieron datos clínicos y resultados de laboratorio. Las características y puntuaciones de la TC se evaluaron a nivel segmentario según la posición, atenuación y forma de las lesiones. Las puntuaciones se calcularon en función del tamaño de la lesión por neumonía, que se calificó en el rango de 1 a 4. También se evaluaron el broncograma de aire, el signo de árbol en brote, el patrón de pavimentación loco, la línea

curvilínea subpleural, la bronquiectasia, el espacio aéreo, el derrame pleural y la linfadenopatía mediastínica y/o hilar.” (Qi et al., 2020) en los resultados encontraron que “el análisis de regresión logística multivariante mostró que el historial de exposición ( $\beta = 3.095$ , odds ratio (OR) = 22.088), el recuento de leucocitos ( $\beta = - 1.495$ , OR = 0.224), el número de segmentos con lesiones periféricas ( $\beta = 1.604$ , OR = 1.604), y el patrón de pavimento loco ( $\beta = 2.836$ , OR = 2.836) se utilizaron para establecer el modelo predictivo para identificar a los pacientes positivos para COVID-19 ( $p < 0.05$ ). En este modelo, los valores del área bajo curva (AUC) en los grupos de entrenamiento y prueba fueron 0,910 y 0,914, respectivamente ( $p < 0,001$ ). Se calculó una puntuación predictiva para COVID-19 (PSC-19) basada en el modelo predictivo mediante la siguiente fórmula: PSC-19 = 2 × historial de exposición (0-1 punto) - 1 × recuento de leucocitos (0-2 puntos) + 1 × lesiones periféricas (0-1 punto) + 2 × patrón de pavimento loco (0-1 punto), con un punto de corte óptimo de 1 (sensibilidad, 88,5%; especificidad, 91,7%). Nuestro modelo predictivo y el PSC-19 pueden aplicarse para la identificación de los casos positivos de COVID-19, ayudando a los médicos y radiólogos hasta recibir los resultados de las pruebas de la reacción en cadena de la polimerasa de transcripción inversa (RT-PCR).” (Qin et al., 2020)

### Estudios clínicos en curso

Los estudios clínicos registrados en clinical trials al 3 de julio de 2020 sobre sistemas de puntuación aún no han iniciado y no tienen resultados aún.

**Tabla 5. Estudios sobre puntuación clínica en COVID-19 registrados en Clinical Trials**

NCT Number	Title	Conditions	Interventions	Study Type	Locations
NCT04372199	Severity score for covid-19 pneumonia	COVID Pneumonia		Observational	Massimo Montalto, Roma, Italy
NCT04362345	Clinical Features and Risk Factors Associated With Worse Outcome in Patients Hospitalized for Covid-19 Pneumonia	Covid-19		Observational	Service des Maladies Infectieuses et Tropicales, Strasbourg, France
NCT04394793	Low Dose Radiation Therapy for Covid-19 Pneumonia	COVID-19 Pneumonia	Radiation: Low dose radiation therapy	Interventional	All India Institute of Medical Sciences, New Delhi, New Delhi, Delhi, India
NCT04418128	Clinical Efficacy of Nafamostat Mesylate for COVID-19 Pneumonia	Corona Virus Infection COVID-19	Drug: Nafamostat Mesylate	Interventional	
NCT04322565	Colchicine Counteracting Inflammation in COVID-19 Pneumonia	Coronavirus Infections Pneumonia, Viral	Drug: Colchicine	Interventional	Azienda Ospedaliero Universitaria di Parma, Parma, PR, Italy
NCT04358406	Rhu-pGSN for Severe Covid-19 Pneumonia	Sars-CoV2	Drug: Recombinant human plasma gelsolin (Rhu-pGSN) Other: Placebo	Interventional	

Fuente: clinical trials (2020)

### Posiciones de Organismos de Salud

Nice recomienda usar su Guía rápida de COVID-19: manejo de la neumonía presunta o confirmada en adultos de la comunidad que incluye esta calculadora [de alerta temprana \(EWNS\)](#).

### Conclusiones / Recomendaciones generales:

- La evidencia sobre el uso del sistemas de puntuación clínica en el diagnóstico de COVID-19 no es de calidad suficiente aún.



### Recomendaciones para los profesionales de la salud:

- El sistemas de puntuación que se puede usar mientras se desarrolla evidencia más robusta es la [calculadora de alerta temprana \(EWNS\)](#)

### Recomendaciones para comunidad:

- El uso de sistemas de puntuación a la fecha son de uso médico y de resultados interpretables sólo por especialistas en la materia.

### Bibliografía

1. Altmayer, S., Zanon, M., Pacini, G. S., Watte, G., Barros, M. C., Mohammed, T. L., Verma, N., Marchiori, E., & Hochegger, B. (2020). Comparison of the computed tomography findings in COVID-19 and other viral pneumonia in immunocompetent adults: a systematic review and meta-analysis. *European radiology*, 1–12. Advance online publication. <https://doi.org/10.1007/s00330-020-07018-x>
2. Birkner, M. D., Kalantri, S., Solao, V., Badam, P., Joshi, R., Goel, A., Pai, M., & Hubbard, A. E. (2007). Creating diagnostic scores using data-adaptive regression: An application to prediction of 30-day mortality among stroke victims in a rural hospital in India. *Therapeutics and clinical risk management*, 3(3), 475–484.
3. Clinical Trials. (2020). Búsqueda: scoresfor COVID-19. Consultado el 3 de julio de 2020 en <https://clinicaltrials.gov/ct2/results?cond=COVID-19&term=SEVERITY+SCORE+FOR+COVID-19+PNEUMONIA&cntry=&state=&city=&dist=>
4. Deeks, J. J., Dinnes, J., Takwoingi, Y., Davenport, C., Spijker, R., Taylor-Phillips, S., Adriano, A., Beese, S., Dretzke, J., Ferrante di Ruffano, L., Harris, I. M., Price, M. J., Ditttrich, S., Emperador, D., Hooft, L., Leeflang, M. M., Van den Bruel, A., & Cochrane COVID-19 Diagnostic Test Accuracy Group (2020). Antibody tests for identification of current and past infection with SARS-CoV-2. *The Cochrane database of systematic reviews*, 6, CD013652. <https://doi.org/10.1002/14651858.CD013652>
5. Huang, D., Wang, T., Chen, Z., Yang, H., Yao, R., & Liang, Z. (2020). A novel risk score to predict diagnosis with coronavirus disease 2019 (COVID-19) in suspected patients: A retrospective, multicenter, and observational study. *Journal of medical virology*, 10.1002/jmv.26143. Advance online publication. <https://doi.org/10.1002/jmv.26143>
6. Kawamoto, K., Houlihan, C. A., Balas, E. A., & Lobach, D. F. (2005). Improving clinical practice using clinical decision support systems: a systematic review of trials to identify features critical to success. *BMJ (Clinical research ed.)*, 330(7494), 765. <https://doi.org/10.1136/bmj.38398.500764.8F>
7. Medic, G., Kosaner Kließ, M., Atallah, L., Weichert, J., Panda, S., Postma, M., & El-Kerdi, A. (2019). Evidence-based Clinical Decision Support Systems for the prediction and detection of three disease states in critical care: A systematic literature review. *F1000Research*, 8, 1728. <https://doi.org/10.12688/f1000research.20498.2>
8. Mei, X., Lee, H. C., Diao, K. Y., Huang, M., Lin, B., Liu, C., Xie, Z., Ma, Y., Robson, P. M., Chung, M., Bernheim, A., Mani, V., Calcagno, C., Li, K., Li, S., Shan, H., Lv, J., Zhao, T., Xia, J., Long, Q., ... Yang, Y. (2020). Artificial intelligence-enabled rapid diagnosis of patients with COVID-19. *Nature medicine*, 10.1038/s41591-020-0931-3. Advance online publication. <https://doi.org/10.1038/s41591-020-0931-3>

9. National Institute for Clinical Excellence (NICE). (2020). COVID-19 rapid guideline: managing suspected or confirmed pneumonia in adults in the community. NICE guideline [NG165]. Consultado el 2 de julio de 2020 en <https://www.nice.org.uk/guidance/ng165>
10. Palen, T. E., Sharpe, R. E., Jr, Shetterly, S. M., & Steiner, J. F. (2019). Randomized Clinical Trial of a Clinical Decision Support Tool for Improving the Appropriateness Scores for Ordering Imaging Studies in Primary and Specialty Care Ambulatory Clinics. *AJR. American journal of roentgenology*, 213(5), 1015–1020. <https://doi.org/10.2214/AJR.19.21511>
11. Qin, L., Yang, Y., Cao, Q., Cheng, Z., Wang, X., Sun, Q., Yan, F., Qu, J., & Yang, W. (2020). A predictive model and scoring system combining clinical and CT characteristics for the diagnosis of COVID-19. *European radiology*, 1–11. Advance online publication. <https://doi.org/10.1007/s00330-020-07022-1>
12. Singh, D., Kumar, V., Vaishali, & Kaur, M. (2020). Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks. *European journal of clinical microbiology & infectious diseases : official publication of the European Society of Clinical Microbiology*, 39(7), 1379–1389. <https://doi.org/10.1007/s10096-020-03901-z>
13. Smith G. B. (2020). National Early Warning Score (NEWS) 2. Consultado el 3 de julio en <https://www.mdcalc.com/national-early-warning-score-news-2>.
14. Urwin S., Kandola G., Graziadi S..(2020). What prognostic clinical risk prediction scores for COVID-19 are currently available for use in the community setting?. Consultado el 3 de julio de 2020 en
15. Wynants, L., Van Calster, B., Collins, G. S., Riley, R. D., Heinze, G., Schuit, E., Bonten, M., Damen, J., Debray, T., De Vos, M., Dhiman, P., Haller, M. C., Harhay, M. O., Henckaerts, L., Kreuzberger, N., Lohman, A., Luijken, K., Ma, J., Andaur, C. L., Reitsma, J. B., ... van Smeden, M. (2020). Prediction models for diagnosis and prognosis of covid-19 infection: systematic review and critical appraisal. *BMJ (Clinical research ed.)*, 369, m1328. <https://doi.org/10.1136/bmj.m1328>
16. Zheng, Z., Peng, F., Xu, B., Zhao, J., Liu, H., Peng, J., Li, Q., Jiang, C., Zhou, Y., Liu, S., Ye, C., Zhang, P., Xing, Y., Guo, H., & Tang, W. (2020). Risk factors of critical & mortal COVID-19 cases: A systematic literature review and meta-analysis. *The Journal of infection*, S0163-4453(20)30234-6. Advance online publication. <https://doi.org/10.1016/j.jinf.2020.04.021>