

Una Aplicación del Delphi de Nube en la Percepción Subjetiva del Pico de la COVID-19

A Cloud Delphi Application to the Subjective Perception of COVID-19 Peak

Miguel Cruz Ramírez^{1*}

Resumen El método Delphi tiene su origen en el campo de la prospectiva, pero su uso se ha extendido a otros ámbitos durante los últimos años. Una de las mejoras para disminuir las deficiencias metodológicas y epistémicas de este método, implica la consideración de modelos difusos en la percepción del panel, junto a elementos de incertidumbre/aleatoriedad. El Delphi de Nube trata de conciliar ambos aspectos. En el presente trabajo, se muestra una aplicación de este enfoque en la percepción subjetiva de un panel de conformación heterogénea, acerca del posicionamiento del pico en la COVID-19 en Cuba. Los resultados se comparan con un modelo de distribución gaussiano bimodal.

Abstract The Delphi method has its origin in the field of forecasting, but its use has spread to other areas in recent years. One of the improvements to reduce the methodological and epistemic deficiencies of this method involves the consideration of fuzzy models in the panel's perception, together with elements of uncertainty randomness. The Cloud Delphi tries to reconcile both aspects. In the present work, an application of this approach is shown in the subjective perception of a panel with heterogeneous integration, about the positioning of the peak in the COVID-19 in Cuba. The results are compared with two-component gaussian mixture distribution.

Palabras Clave

COVID-19, Delphi de Nube, percepción, modelos gaussianos mixtos, paquete R

Keywords

COVID-19, Cloud Delphi, perception, gaussian mixture distribution, package R

¹Departamento de Matemática, Universidad de Holguín, Cuba, mcruzr@uho.edu.cu

*Autor para Correspondencia, Corresponding Author

Introducción

El 31 de diciembre de 2019, la República Popular China informa a la OMS (Organización Mundial de la Salud) acerca de la proliferación de varios casos de una pulmonía con etiología desconocida, detectada en la ciudad de Wuhan en la provincia de Hubei [1]. A solo un mes, el 31 de enero de 2020, ya se alcanzaban 9776 infestados en varios países, con 213 fallecidos, por lo cual la OMS declaró el brote epidémico como una emergencia de salud pública de carácter internacional [2]. La pandemia es causada por un nuevo coronavirus SARS-CoV-2, conforme a la terminología empleada por el Comité Internacional de Taxonomía de Virus. Luego de transcurrir siete meses, el Centro de Ciencia e Ingeniería de Sistemas de la Universidad Johns Hopkins reportaba la propagación por 214 territorios, entre países y tierras de ultramar, con más de 12.2 millones de contagiados, mientras que la cifra global de decesos superaba las 556 mil personas.

La comunidad científica mundial desplegó inmediatamente

te un arduo trabajo investigativo para combatir la pandemia, bajo perspectivas disímiles. En particular, numerosos modelos matemáticos de carácter local o global aparecieron desde los mismos inicios de esta emergencia de salud [3, 4, 5]. En la literatura existe una amplia variedad de modelos matemáticos, dirigidos a explicar y predecir los fenómenos epidemiológicos, en su mayoría de tipo determinista, aunque algunos toman en consideración la naturaleza estocástica no lineal de ciertos procesos subyacentes [6]. Por ejemplo, uno de los modelos deterministas más empleado es el modelo SIR (*Susceptible-Infectious-Recovered*), desarrollado originalmente por Kermack y McKendrick en 1927 [7]. La dinámica de este modelo, se expresa por medio de un sistema de ecuaciones diferenciales que explica la evolución de la enfermedad en el tiempo, con base en parámetros relevantes, tales como el número básico de reproducción y la tasa de recuperación. En general, los modelos no lineales de crecimiento culminan con el ajuste de curvas, como el caso de la curva logística, log-logística, de crecimiento exponencial de Gompertz, de

Weibull, de Bertalanffy, entre otras muchas [5, 8, 9, 10].

En Cuba, el agente microbiano de la COVID-19 fue detectado por primera vez el 11 de marzo de 2020. No obstante, ya el país venía adoptando medidas para enfrentar la pandemia como la aprobación del Plan para la Prevención y Control del Coronavirus, el 29 de enero, por parte del Consejo de Ministros. Desde el punto de vista científico, se creó el Grupo de Ciencia para el enfrentamiento a la COVID-19, el Observatorio de Salud COVID-19 y un Comité de Innovación. Al inicio de junio, ya se contaba con 460 investigaciones relacionadas con la enfermedad y sus formas de propagación [11].

En un artículo publicado en los Anales de la Academia de Ciencias de Cuba, el presidente Miguel Díaz-Canel y el académico Jorge Núñez Jover destacaban: «el relevante papel que han desempeñado la ciencia y la tecnología nacionales, orgánicamente vinculadas con la gestión gubernamental, todos en función de ofrecer una respuesta social, científica, política y sanitaria capaz de enfrentar el desafío que la pandemia ha planteado» [11]. Como parte de este esfuerzo conjunto, Comunidad Científica - Gobierno, la investigación matemática ocupó un importante lugar.

Las representaciones estadísticas de la pandemia ganaron la atención de toda la población, enfrascada en el cumplimiento de innumerables medidas de precaución. Un tema diario de máxima audiencia televisiva, consistió en la información del número de fallecidos, el total de nuevos casos confirmados, localización por provincias, entre otros datos emitidos oficialmente por la Dirección Nacional de Epidemiología, del Ministerio de Salud Pública. Como parte de este proceso, al igual que en otros países, un tema de interés consistió en la determinación del «pico», o valor máximo de contagiados en el periodo de pandemia. Varios modelos matemáticos mostraron la importancia de plantear más de un escenario, de manera que se adoptaran medidas prospectivas para reducir el contagio y acercar la evolución a la variante más favorable, sin perder tampoco la mira en la necesidad de prepararse para enfrentar la variante más desventajosa.

El presente trabajo tiene como objetivo explorar la percepción subjetiva del posicionamiento del pico de pandemia aspecto que, si bien cuenta con argumentos matemáticos rigurosos, también puede enfocarse bajo una perspectiva de naturaleza psicosocial. Seguidamente se presentan ambos enfoques. En el primero se explora el comportamiento de la enfermedad desde el punto de vista estadístico, pero no con fines de pronósticos sino de localización diacrónico-temporal. En el segundo, se presentan los resultados de un estudio Delphi, y se comparan las evidencias empíricas de percepción subjetiva con un modelo matemático objetivo.

1. En busca de una localización objetiva del pico de pandemia

La determinación del pico de pandemia cobra un valor especial, pues facilita la planificación con un mejor empleo de los recursos humanos, materiales y financieros. Por este

motivo, ha sido objeto de atención en investigaciones recientes relacionadas con la COVID-19 [12, 13]. Para localizar el momento en que ocurre un pico, es necesario el empleo de modelos matemáticos eficientes. En particular, la modelación del proceso de infección del SARS-CoV-2 ha enfrentado no pocas dificultades a escala mundial [2].

Algunas problemáticas están relacionadas con la fiabilidad de la información, otras con el número de parámetros y variables explicativas, e incluso con el dilema de seleccionar el modelo matemático más adecuado. Una vez escogido el modelo, suelen emplearse técnicas de análisis numérico, tales como el método de mínimos cuadrados, con el objetivo de conseguir un ajuste de curvas que minimice el error cuadrático [5]. En el caso de la COVID-19, se han implementado principalmente modelos SIR clásicos antes mencionados, modelos basados en series cronológicas, modelos predictivos a través de internet con uso de *Big Data*, y modelos basados en inteligencia artificial y *Machine Learning* [8].

El presente análisis se desarrolla tomando en consideración el número de casos diarios reportados en el portal *Covid19CubaData*, transcurridos cerca de cuatro meses de pandemia. Para el procesamiento de la información, se utiliza el paquete `mixtools`, del lenguaje estadístico R [14]. Dicho paquete está equipado de herramientas desarrolladas a partir de investigaciones recientes, las cuales flexibilizan o modifican el supuesto de normalidad.

La característica fundamental que distingue a `mixtools` de sus similares en R, consiste en el desarrollo de técnicas computacionales para el análisis de modelos mixtos finitos, cuyos componentes son regresiones y vectores multinomiales originados de la discretización de datos multivariados, e incluso de distribuciones que casi no se especifican por completo [14]. En el presente estudio se adopta el supuesto de normalidad, por ello se implementa la función `normalmixEM` basada en el Algoritmo de Maximización de la Esperanza (*Expectation Maximization Algorithm*) [15], el cual sugiere una distribución bimodal D .

Si se denota por μ_i y σ_i ($i \in \{1, 2\}$) los parámetros de localización y de escala, respectivamente, entonces μ_i sirve para estimar la abscisa de cada pico en la distribución bimodal D , cuya función de densidad puede representarse como una expresión dependiente de sendas distribuciones latentes D_1 y D_2 [16] en función del tiempo t :

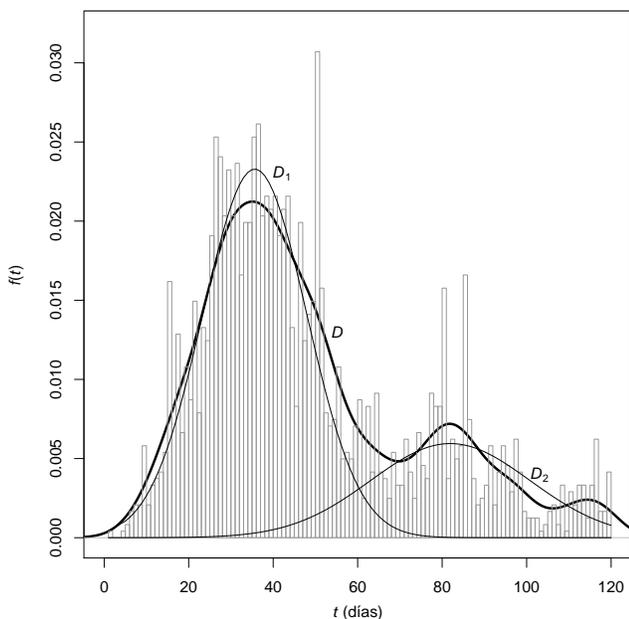
$$f(t|\lambda, \mu_1, \sigma_1, \mu_2, \sigma_2) = \lambda D_1(t|\mu_1, \sigma_1) + (1 - \lambda) D_2(t|\mu_2, \sigma_2)$$

Con la implementación del comando `summary`, se obtienen los valores de la función `normalmixEM`, resumidos en la Tabla 1 para 51 iteraciones.

Ello significa que el pico mayor tuvo lugar alrededor del trigésimo sexto día de pandemia ($\mu_1 \approx 36$), o sea, el martes 14 de abril. El segundo pico vendría ocurriendo cerca del octavo segundo día ($\mu_2 \approx 82$), que es el domingo 31 de mayo. Ambos picos teóricos corresponden, respectivamente a las distribuciones D_1 y D_2 que son componentes simples gaussianas de la distribución D . La Figura 1 ilustra estos resultados.

Tabla 1. Parámetros de la distribución bimodal D

Parámetro	D_1	D_2
λ_i	0.71824	0.28176
μ_i	35.65215	81.92520
σ_i	12.30496	18.89894

**Figura 1.** Evolución de la pandemia (120 días)

Como suele ocurrir, no coinciden exactamente los valores esperados con los observados. En el caso de los picos reales, el máximo valor observado para el componente gaussiano D_1 ocurre el 1ro de mayo, con 74 casos, mientras que el correspondiente a D_2 tiene lugar el 5 de junio, con 40 casos. A partir de aquí, resulta interesante explorar cómo se reflejan estas evidencias empíricas en la cognición humana, a fin de comparar la percepción subjetiva con la modelación teórica. Con base en su naturaleza prospectiva, el método Delphi puede allanar el camino para emprender esta exploración.

2. El método Delphi de Nube

El método Delphi tiene su origen en la corporación Rand de los Estados Unidos, y es el resultado de varios estudios orientados hacia la mejora de pronósticos, emitidos por un panel de expertos. En su versión más convencional, este método se caracteriza por cuatro aspectos demarcatorios: el anonimato del panel de expertos, la iteración en el procesamiento de datos (apoyado fundamentalmente en encuestas estructuradas), la retroalimentación controlada (*feedback*), y la respuesta estadística de grupo. Un grupo coordinador funge como responsable de elaborar los cuestionarios, circularlos, sintetizar la información y devolverla al panel. Las condiciones de parada son disímiles y van desde la adopción previa de un

número prefijado de rondas, hasta el cálculo de estadígrafos relacionados con el procesamiento de la información [17, 18].

Bajo denominaciones diversas, tales como «proceso Delphi», «técnica Delphi», «ejercicio Delphi», «estudio Delphi», entre otras, este método ha sido empleado recientemente en investigaciones relacionadas con el enfrentamiento a la pandemia de la COVID-19. Por ejemplo, en la búsqueda de consenso acerca de la rehabilitación pulmonar en pacientes que rebasan la etapa de cuidados intensivos (20 panelistas de 5 países) [20]; o consenso acerca de qué procedimiento de endoscopia gastrointestinal deberían ser aplicados durante la pandemia, y cuáles podrían resultar seguros sin ocasionar secuelas posteriores (14 panelistas) [19].

También se reporta una investigación donde participan 13 instituciones de 11 países europeos, relacionada con la recopilación expedita de información experta, sobre guías prácticas para tratar con cautela a los niños con complicaciones ocasionadas por enfermedades renales crónicas [21]. En este caso, el método Delphi no solo resulta útil para la sistematización de información con relativa inmediatez, sino que compensa el manejo de datos limitados ya que los niños representan menos del 1% de los casos reportados.

Por otro lado, un amplio estudio realizado por la WSRI (*Welsh Surgical Research Initiative*, 339 participantes de 41 países), encontró elevados niveles de consenso en relación a muchos aspectos relacionados con los protocolos de tratamiento de la COVID-19, pero identificó varias áreas contenciosas, las cuales representan objetivos de investigación urgente para delinear prácticas más seguras en el salón de operaciones [22].

Con más de medio siglo de historia, el método Delphi ha experimentado una amplia diversificación en sus características y también en sus ámbitos de aplicación [23]. Entre la modificaciones más recientes se encuentran los enfoques no deterministas [24], como las numerosas variantes del Delphi Fuzzy que registra la literatura.

La principal dificultad del Delphi convencional reside en sus escasas posibilidades para captar la ambigüedad y la incertidumbre, por un camino frecuentemente indeterminista. Por ejemplo, en la evaluación de ciertos ítems a los sujetos se les solicita, como norma, la selección de etiquetas lingüísticas en lugar de valores numéricos concretos. Luego, el significado de las etiquetas puede reflejarse de modo distinto en cada subjetividad, mientras que la escala adoptada no siempre es resultado de una estandarización previa [25].

Ni siquiera el enfoque difuso clásico resuelve los problemas epistémicos de aprehensión de la información fiable y válida [26]. Las respuestas de los sujetos suelen ser de naturaleza *crisp* (rígida) y no fuzzy, mientras que el correspondiente acto de selección viene acompañado de cierta incertidumbre, asociada al dilema de localizar el valor más probable dentro de un *continuum* subjetivo. Existen numerosas alternativas que tratan de palear la falencia de lo borroso como aleatorio, el determinismo imperante en la selección de las funciones de pertenencia, e incluso de prescindir del supuesto lógico del tercero excluido [26]. Una de estas alternativas es relati-

vamente reciente y consiste en el Modelo de Nube, el cual se define como sigue [25, 27]:

Definición 1 Dado un concepto cualitativo T , definido sobre un universo de discurso $U = \{u\}$, sea $x \in U$ una instancia aleatoria del concepto T y $\mu_T(x) \in [0, 1]$ el grado de certidumbre de x a lo largo de T , el cual corresponde a un número aleatorio con una tendencia estable. Entonces, la distribución de x en el universo U puede definirse como una nube y x constituye «una gota» de la nube.

Se cumple que para todo $x \in U$, la aplicación $\mu_T(x)$ es no inyectiva por su propia naturaleza. O sea, el grado de certeza de x a lo largo del concepto T es una distribución de probabilidad, en lugar de constituir un valor fijo. Este modelo se apoya en tres conceptos básicos:

- la expectativa (Ex), consistente en la esperanza matemática de que las gotas de la nube pertenezcan a un concepto del universo;
- la entropía (En), que expresa la medida borrosa de un concepto cualitativo, como ámbito de cobertura del universo subsumido por el concepto;
- y la hiper-entropía (He), que es el grado de incertidumbre de la entropía, y refleja la dispersión de las gotas de la nube.

Con base en estos tres parámetros, Li, Liu y Gan [27] desarrollan un algoritmo denominado NCG (*Normal Cloud Generator*). En efecto, si N es el número de gotas de la nube, para el cálculo del valor de la función $NCG(Ex, En, He, N)$, tiene lugar el algoritmo descrito en la Tabla 2.

Tabla 2. Algoritmo para el Modelo de Nube

Función: $NCG(Ex, En, He, N)$

Entrada: Tres parámetros Ex, En, He , y el número de gotas N de la nube.

Salida: N gotas de la nube con su grado de incertidumbre.

Pasos:

1. Se genera un número aleatorio En'_i distribuido normalmente, cuya esperanza es En y su varianza He^2 .
2. Se genera un número aleatorio x_i distribuido normalmente, cuya esperanza es Ex y su varianza $(En'_i)^2$.
3. Se calcula el grado de incertidumbre:

$$y_i = \varphi(t_i) = e^{-\frac{(t_i - Ex)^2}{2(En'_i)^2}}$$

4. Se obtiene la i -ésima gota $drop(t_i, y_i)$ de la nube.
5. Se repite el ciclo 1-4, hasta generar las N gotas.

Desde el punto de vista gráfico, el posicionamiento ideal del «eje de simetría» de la nube indica su expectativa Ex , el

espesor explica su grado de aleatoriedad y depende de la hiper-entropía He , mientras que la amplitud expresa su grado de borrosidad y depende la entropía En . Aquí resulta práctico el empleo de la regla « 3σ », o sea, bajo una distribución normal, si σ expresa la desviación típica y μ la media, entonces el intervalo $[\mu - 3\sigma, \mu + 3\sigma] \subset \mathbb{R}$ comprende alrededor del 99.74% de toda la distribución. La interpretación gráfica de una nube de puntos se representa en la Figura 2, para el caso particular $NCG(60, 2, .3, 2000)$.

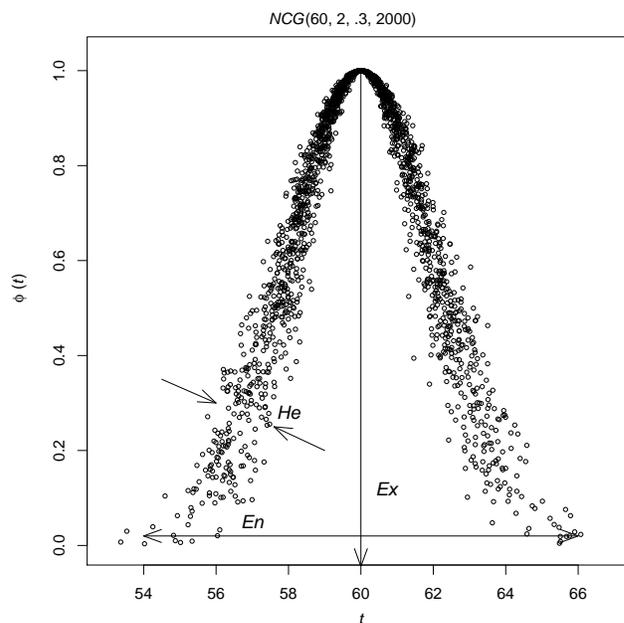


Figura 2. El Modelo de Nube

A partir de esta idea, se define el concepto de «nube normal» [27]:

Definición 2 Si $t \in U$ es la representación aleatoria de un concepto cualitativo \tilde{A} en el universo de discurso U , la cual satisface que $t \sim N(Ex, En'^2)$, donde $En' \sim N(En, He^2)$, y

$$\varphi_{\tilde{A}}(t_i) = e^{-\frac{(t_i - Ex)^2}{2(En'_i)^2}},$$

entonces la distribución de t en U se denomina «nube normal».

Con el fin de definir el Delphi de Nube, Yang, Zeng, y Zhang [28] utilizan el concepto de nube normal. Para el cálculo de los parámetros correspondientes, estos investigadores se apoyan en la aplicación de encuestas de valor de intervalo (*interval-valued surveys*). En efecto, si en un ítem de una encuesta se solicita estimar el valor de cierta variable, entonces se pueden adoptar los criterios siguientes:

- El valor medio del intervalo puede interpretarse como la expectativa Ex .
- La amplitud del intervalo puede reflejar una medida de la entropía En .

- La variación entre intervalos producidos por dos iteraciones sucesivas, puede reflejar el grado de incertidumbre medido por la hiper-entropía He .

Yang, Zeng, y Zhang [28] también utilizan las definiciones de suma y producto de nubes, introducidas por Li y Yi [25] y obtienen una nube sintética explicativa del comportamiento global $\tilde{A}_s(Ex_s, En_s, He_s)$. Este constructo equipara los grados de incidencia de los juicios individuales de los expertos, lo cual no necesariamente es viable en cualquier contexto. En general, el peso de cada opinión depende de:

- los resultados de evaluar la experticia, por intermedio de índices de competencia experta, o bien de
- la consistencia y la estabilidad del juicio emitido en una sucesión de rondas.

Yang, Zeng, y Zhang [28] establecen un mecanismo de ponderación, basado en el segundo criterio. Cada peso individual se determina de modo inversamente proporcional a una suma de tres componentes: el valor modular normalizado de la diferencia entre las expectativas individual y colectiva, la borrosidad del juicio, y la incertidumbre. Así, a partir de las n nubes $\tilde{A}_i(Ex_i, En_i, He_i)$, $1 \leq i \leq n$, correspondientes a cada uno de los expertos, se obtiene una nube promedio ponderada $\tilde{A}_{wa}(Ex_{wa}, En_{wa}, He_{wa})$.

Este procedimiento para el cálculo de los pesos no es único, ni tampoco es ajeno a críticas metodológicas y epistémicas. Por ejemplo, la estabilidad del juicio experto puede obedecer a un pensamiento rígido e inflexible, en lugar de un criterio firme y basado en argumentos plausibles. Sin embargo, dicho procedimiento es útil para el presente trabajo, donde el énfasis no reside en la experticia del panel sino en el estudio de su percepción, contrastada con los modelos matemáticos antes mencionados. En síntesis, el algoritmo que define un Delphi de Nube se presenta en la Tabla 3 [28].

En el segundo paso del algoritmo, nótese que la ecuación de $He_i^{(k)}$ intenta captar en qué medida el juicio del experto i permanece estable, tras dos iteraciones sucesivas $k-1$ y k . Si la respuesta k -ésima produce un intervalo que es subconjunto del $(k-1)$ -ésimo, resulta que $He_i^{(k)} = 0$ para el experto i . En todos los restantes casos se obtiene un valor mayor que cero. Además, a mayor incertidumbre/aleatoriedad, mayor será la hiper-entropía.

3. Método

La presente investigación no tiene el propósito de establecer mecanismos efectivos de pronóstico, a partir del conocimiento experto. Por el contrario, el objetivo se centra en el estudio de la percepción de un panel reducido y de conformación heterogénea, acerca del posicionamiento del pico en la COVID-19 en Cuba. Participan cinco panelistas, seleccionados con base en los siguientes criterios:

- nivel cultural universitario en áreas heterogéneas, sin formación avanzada en estadística,

Tabla 3. Algoritmo para el Delphi de Nube

Función: $NCD(Ex, En, He, N)$

Entrada: Tres parámetros Ex, En, He , y el número N de gotas de la nube, así como i segmentos $[l_i^{(k)}, u_i^{(k)}] \subset \mathbb{R}$, que constituyen las evaluaciones del panel de i expertos ($1 \leq i \leq n$) en la ronda k , de cierto aspecto consignado en una encuesta.

Salida: La nube sintética $\tilde{A}_{wa}^{(k)}$, correspondiente a la ronda k , basada en la ponderación w_i de cada juicio experto; y las i -ésimas parejas respectivas de índices de estabilidad $\Delta En_i^{(k)}$ y consistencia $Unc_i^{(k)}$, después de la ronda k .

Pasos:

- Se inicia el contador de iteración ($k = 1$).
- Se obtiene una nube $NCG_i^{(k)}(Ex_i^{(k)}, En_i^{(k)}, He_i^{(k)}, N)$ para la respuesta k -ésima del experto i -ésimo, donde $Ex_i^{(k)} = (u_i^{(k)} + l_i^{(k)})/2$, $En_i^{(k)} = (u_i^{(k)} - l_i^{(k)})/6$. En el caso de $He_i^{(k)}$, si $k = 1$ entonces $He_i^{(1)} = En_i^{(1)}/K$, donde K es una constante predefinida; y si $k > 1$, entonces $He_i^{(k)} = [\max\{u_i^{(k)} - u_i^{(k-1)}, 0\} + \max\{l_i^{(k-1)} - l_i^{(k)}, 0\}]/6$.
- Se calculan los componentes $w_i^{(k)'} = [Ex_i^{(k)} - Ex_s^{(k)}]/[Ex_s^{(k)} + He_i^{(k)}]^{-1}$, los cuales se normalizan por intermedio de los cocientes $w_i^{(k)} = w_i^{(k)'}/\sum_{1 \leq i \leq n} w_i^{(k)'}$, resultando un vector peso normalizado.
- Se genera información retroalimentada (*feedback*) por medio de dos procedimientos de agregación: uno para determinar la nube sintética $\tilde{A}_s^{(k)} = NCG_s^{(k)}(Ex_s^{(k)}, En_s^{(k)}, He_s^{(k)}, N)$, y otro para expresar cada nube promedio ponderada $\tilde{A}_{wa}^{(k)} = NCG_{wa}^{(k)}(Ex_{wa}^{(k)}, En_{wa}^{(k)}, He_{wa}^{(k)}, N)$, donde N constituye el número de gotas.
- Se calcula una pareja de índices para controlar la estabilidad y consistencia del juicio experto: uno consiste en la diferencia normalizada entre entropías consecutivas (ΔEn), y el otro es el grado de incertidumbre normalizado (Unc). Se obtienen de la siguiente manera: $\Delta En_i^{(k)} = |En_i^{(k-1)} - En_i^{(k)}|/En_i^{(k-1)}$, con $\Delta En_i^{(1)} = En_i^{(1)}$, y $Unc_i^{(k)} = He_i^{(k)}/En_i^{(k)}$, $1 \leq i \leq n$.
- Se establece la condición de parada $\Delta En_i^{(k)} \leq \delta$ (prefijado de antemano) y $Unc_i^{(k)} = 0$. En caso de que un experto no cumpla dichas condiciones, el experimentador adopta decisiones puntuales.
- $k \leftarrow k + 1$, dando paso a la siguiente ronda Delphi.

- familiarización con los partes actualizados de la COVID-19 en Cuba, emitidos por el Ministerio de Salud Pública,

- disposición a participar en la investigación.

El estudio se desarrolla durante los dos primeros meses de evolución de la pandemia, lo cual se enmarca dentro del periodo descrito por el modelo D_1 en las inmediaciones del primer pico. Los integrantes seleccionados reciben tres cuestionarios, contentivos de dos requerimientos: determinar la fecha máxima antes de la cual no podría ocurrir el pico de pandemia, así como la fecha mínima después de la cual este no tendría lugar. Esencialmente, la respuesta de cada panelista no es más que la demarcación de un periodo perceptivo de días, contenido del pico de pandemia. O sea, el mejor acotamiento percibido en el momento de recibir el cuestionario correspondiente. Para emitir sus respuestas, los participantes no reciben el *feedback* típico de un Delphi convencional, sino la información actualizada de los partes oficiales.

Los cuestionarios se aplican con intermedio de 20 días aproximadamente. Las fechas de realización son las siguientes: martes 31 de marzo, lunes 20 de abril, y lunes 11 de mayo. En cada caso, se toma en consideración que los reportes oficiales actualizan la información hasta el día anterior. Las respuestas de los cuestionarios se reciben en un término de tres días naturales, por la vía del correo electrónico.

Como puede apreciarse, en el presente estudio se entremezclan elementos que tipifican un Delphi de Nube, con ciertas modificaciones. En efecto:

- Se conserva el anonimato del panel para eliminar efectos negativos de intervenciones dominantes, pero se flexibiliza el concepto de experto al considerar apenas una formación estadística muy elemental. El nivel de competencia comprende dos capacidades mínimas: comprender la pregunta y emitir una respuesta razonable.
- Se sustenta la iteración por intermedio de rondas de encuestas estructuradas, pero el objeto de análisis no enfatiza el pronóstico sino la percepción.
- Se mantiene la retroalimentación controlada (*feedback*), pero la devolución de información al panel no sintetiza la opinión colectiva, sino que proviene de información externa consistente en la evolución real de la enfermedad.
- Se remarca la respuesta estadística de grupo, pero el procesamiento de esta información pone por delante el Modelo de Nube en lugar de estadígrafos tradicionales.
- La condición de parada no busca convergencia de criterios ni consenso colectivo, sino que se apoya en el análisis de la consistencia y la estabilidad del juicio individual. Se prefija el número de rondas y se examina el comportamiento de los indicadores mencionados.

Para el procesamiento de la información se utiliza la función *CloudDelphi* [29] escrita sobre R, la cual está diseñada para graficar nubes múltiples en cada ronda Delphi, con

prestaciones gráficas flexibles, y también para exportar los parámetros fundamentales de la función $NCD(Ex, En, He, N)$, antes descrita en el algoritmo de la Tabla 3.

4. Resultados y discusión

Después de completar las tres rondas, las respuestas emitidas por el panel aparecen en la Tabla 4, donde las fechas han sido sustituidas por los numerales correspondientes a la evolución diacrónica de la pandemia. Por ejemplo, el intervalo [30, 35] significa el periodo comprendido entre el 9 y el 14 de abril, o sea, entre el trigésimo y el trigésimo quinto día respectivamente.

Tabla 4. Respuestas del panel en cada ronda

Participante	Ronda 1	Ronda 2	Ronda 3
Nº 1	[30, 35]	[37, 39]	[37, 53]
Nº 2	[25, 39]	[30, 36]	[25, 45]
Nº 3	[40, 50]	[30, 38]	[35, 55]
Nº 4	[32, 38]	[33, 40]	[35, 42]
Nº 5	[50, 60]	[36, 39]	[38, 52]

Como puede apreciarse, la primera ronda expresa una especie de pronóstico personal de lo que va a ocurrir. Todos los intervalos se ubican en días posteriores a la aplicación del primer instrumento. Ello indica que la percepción es de naturaleza «prospectiva», en el sentido de configurar un escenario futuro basado en el ritmo de crecimiento, en los modelos divulgados por diversos medios de comunicación, así como la autovaloración personal de la capacidad del país para enfrentar la pandemia. Toda esta información se refleja en la primera estimación. La Figura 3 combina las nubes individuales con una nube promedio ponderada, tal como se describe en el algoritmo descrito en la Tabla 3.

Las percepciones individuales son dispares y ubican el pico entre el primer y segundo mes de pandemia. Los parámetros correspondientes a la nube sintética son $Ex = 39.90$, $En = 5.83$, $He = .25$. A priori, el panel percibe el pico en una posición intermedia entre el valor teórico y el observado, constatados a posteriori. En este momento, las diferencias normalizadas de las entropías individuales cumplen $.83 \leq \Delta En_i^{(1)} \leq 2.33$, mientras que todos los grados normalizados de incertidumbre satisfacen $Un_i^{(1)} = .17 (1 \leq i \leq 5)$.

La realización de la segunda ronda ocurre en el cuadragésimo día, donde se percibía una especie de meseta con ligera tendencia al decrecimiento del número de casos confirmados. La percepción colectiva retrasa ahora el pico hacia $Ex = 35.80$, como se muestran en la Figura 4.

Al examinar los parámetros individuales de estabilidad y consistencia, se tiene que $.17 \leq \Delta En_i^{(2)} \leq .70$, y $.00 \leq Un_i^{(2)} \leq 4.67$. Para el caso de la nube promedio ponderada, la entropía disminuye ($En = 1.67 < 5.83$) y la hiperentropía aumenta ($He = 1.00 > .25$). Lo primero indica mayor coincidencia de

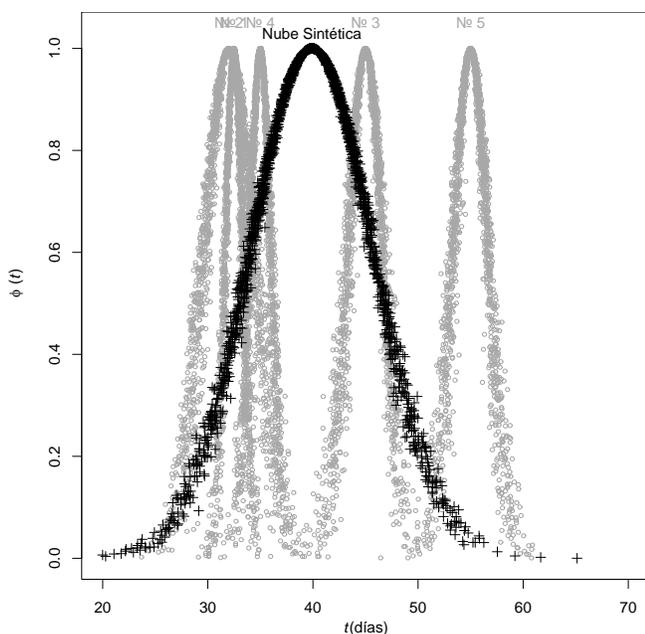


Figura 3. Resultados de la primera ronda Delphi

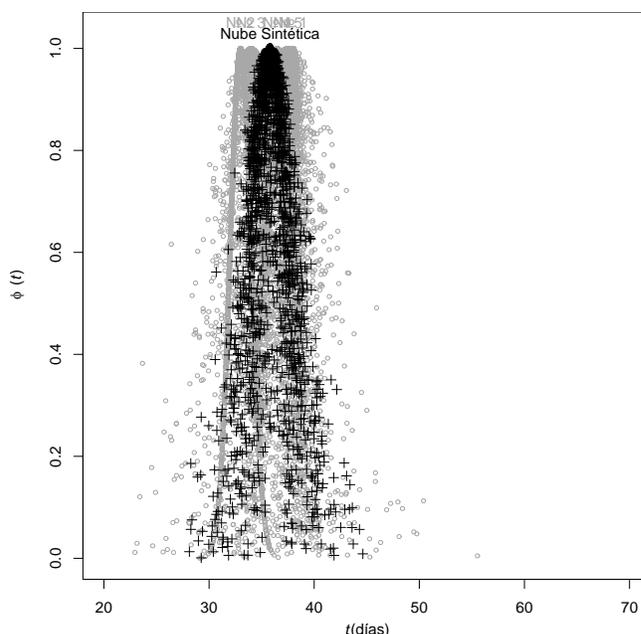


Figura 4. Resultados de la segunda ronda Delphi

critérios, pero lo segundo refleja un cambio global de opinión, en el tránsito de una ronda a otra.

Existen dos elementos que es necesario puntualizar. En primer lugar, la hiperentropía del segundo panelista contrasta con el comportamiento restante. Él sugiere la secuencia de intervalos [25, 39] y [30, 36], de manera que en la segunda ronda reafirma su apreciación inicial con una acotación más precisa ($\Delta En_2^{(2)} = .57$, $Unc_2^{(2)} = .00$). Por tal motivo, el espesor de la nube correspondiente es menor para este participante, como puede observarse en la Figura 4. En segundo lugar, existe un mayor nivel de coincidencia en la percepción colectiva, reflejada en la superposición del conjunto de nubes individuales. Las evidencias sugieren que el panel tiene una percepción de naturaleza «asertiva», una especie de convencimiento de que el pico de la pandemia va quedando atrás.

La última ronda se desarrolla en el sexagésimo día. Aunque ya es apreciable la tendencia al decrecimiento, este periodo comprende la interrupción del 1ro de mayo, donde ocurre el pico real de 74 casos diagnosticados positivos a la COVID-19. Los resultados obtenidos se reflejan en la Figura 5.

La nueva nube promedio ponderada posee parámetros $Ex = 41.70$, $En = 5.00$, $He = 1.87$. Como puede observarse, tanto la entropía como la hiperentropía aumentan. Ello se debe a que las percepciones individuales retornan a un estado de mayor discordancia, tanto inter-sujetos como intra-sujetos, lo cual refleja una especie de movilidad o desequilibrio en el pensamiento. La percepción colectiva cambia, probablemente influida por el valor atípico observado. En cuatro de los cinco casos, los participantes reconfiguran su estimación, postergando principalmente la cota superior. Solo el cuarto de ellos muestra una percepción con mejor estabilidad ($\Delta En_4^{(3)} = .00$) y consistencia ($Unc_4^{(3)} = .29$). Los resultados de la Tabla 4

reflejan que la percepción de este individuo experimenta las menores variaciones, en el conjunto de las tres rondas.

De forma general, en este tercer momento del estudio Delphi, puede afirmarse que el panel adopta una percepción de naturaleza predominantemente «correctiva». Los valores finales de los parámetros aparecen resumidos en la Tabla 5.

5. Conclusiones

El método Delphi ha evolucionado hasta alcanzar niveles de desarrollo muy superiores, especialmente en lo relacionado con el procesamiento estadístico de la información. El Delphi de Nube constituye una idea relativamente reciente, en cuya esencia residen tres conceptos fundamentales: la expectativa, la entropía, y la hiperentropía. Con el presente trabajo, se ilustran las potencialidades del Delphi de Nube para la realización de investigaciones sobre percepción espacio-temporal, específicamente en lo referido a la percepción del pico de la pandemia ocasionada por el SARS-CoV-2.

El estudio adopta algunas modificaciones en la estructura del método, las cuales obedecen al énfasis centrado en el cambio perceptivo del panel participante. Incluso el concepto de experto se modifica, pues no se aspira a emitir pronósticos viables, sino a analizar cómo la percepción cambia en la medida en que evoluciona la enfermedad, durante un periodo de tiempo. Como resultado principal, puede afirmarse que existen evidencias discretas de cambio y modificación perceptiva respecto al posicionamiento del pico de pandemia, en la medida que evoluciona la enfermedad. Estos cambios están condicionados, probablemente, por fenómenos relativamente estables, tales como la ocurrencia de «mesetas» y el cambio sostenido en el ritmo de crecimiento o decrecimiento. Sin embargo, la percepción también puede estar condicionada por

Tabla 5. Parámetros finales del Delphi de Nube ($k = 3$)

Parámetro	Participantes					\tilde{A}_{wa}
	Nº 1	Nº 2	Nº 3	Nº 4	Nº 5	
Ex	45.00	35.00	45.00	38.50	45.00	41.70
En	2.67	3.33	3.33	1.17	2.33	5.00
He	2.33	1.67	2.83	0.33	2.17	1.87
w	.14	.14	.11	.45	.16	1.00
ΔEn	7.08	2.33	1.51	.00	3.67	1.99
Unc	.88	.50	.85	.29	.93	1.93

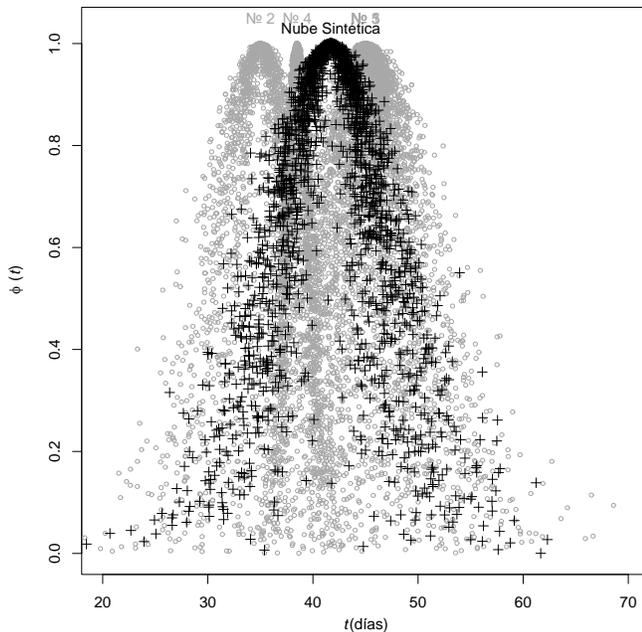


Figura 5. Resultados de la tercera ronda Delphi

específicas para su desarrollo, sino también a la capacidad humana para enfrentarla. Esta capacidad es muy difícil de modelar con recursos matemáticos, especialmente en escenarios relativamente imprevisibles. Justo en este tipo de circunstancias, el método Delphi puede aportar información útil, para complementar los modelos obtenidos con la implementación de otros métodos.

6. Agradecimientos

El autor desea agradecer al panel participante en el presente estudio, especialmente por su generosa y activa colaboración durante la etapa de confinamiento a causa de la pandemia.

eventualidades inesperadas que modifican el reflejo subjetivo del comportamiento diacrónico global.

Otro aspecto interesante consiste en la identificación de tres comportamientos en el panel, condicionados por el ritmo evolutivo y sus contingencias: la percepción «prospectiva», basada en evidencias de construcción de futuro; la percepción «asertiva», donde se manifiesta una especie de adaptación ante evidencias estables; y la percepción «correctiva», donde los sujetos reconfiguran su parecer, motivados por fluctuaciones imprevistas.

La muestra empleada es significativamente limitada y no permite realizar análisis estadísticos fiables, sin embargo, los resultados ayudan a la proyección de investigaciones futuras. Incluso, regresando a los diseños fundacionales del método, la selección de un panel de expertos con competencias centradas en el pronóstico, podría aportar sugerencias útiles acerca del posicionamiento del pico o bien de la extensión en el tiempo de una enfermedad similar.

La evolución de una pandemia de esta naturaleza no solo obedece a leyes naturales de propagación y a condiciones

Referencias

- [1] J.T. Wu, K. Leung, y G.M. Leung, Nowcasting and forecasting the potential domestic and international spread of the 2019-nCoV outbreak originating in Wuhan, China: a modelling study, *Lancet* **395** (2020), 689-697. [https://doi.org/10.1016/S0140-6736\(20\)30260-9](https://doi.org/10.1016/S0140-6736(20)30260-9)
- [2] W.C. Roda, M.B. Varughese, D. Han, y M.Y. Li, Why is it difficult to accurately predict the COVID-19 epidemic? (preprint), *Infectious Disease Modelling* (2020). <https://doi.org/10.1016/j.idm.2020.03.001>
- [3] C. Anastassopoulou, L. Russo, A. Tsakris, y C. Siettos, Data-based analysis, modelling and forecasting of the COVID-19 outbreak, *PLoS ONE* **15**(3) (2020), e0230405. <https://doi.org/10.1371/journal.pone.0230405>
- [4] T.-M. Chen, J. Rui, Q.-P. Wang, Z.-Y. Zhao, J.-A. Cui, y L. Yin, A mathematical model for simulating the phase-based transmissibility of a novel coronavirus, *Infectious Diseases of Poverty* **9**(24) (2020). <https://doi.org/10.1186/s40249-020-00640-3>
- [5] L. Jia, K. Li, Y. Jiang, X. Guo, y T. Zhao, Prediction and analysis of coronavirus disease 2019, *arXiv* (2020). <https://arxiv.org/abs/2003.05447>
- [6] S. Galindo, M.A. Rodríguez, y J.L. Cervantes, Las matemáticas de las epidemias: caso México 2009 y otros, *CIENCIA ergo-sum* **20**(3) (2020), 238-246. <https://cienciaergosum.uaemex.mx/article/view/7038>
- [7] W.O. Kermack, y A.G. McKendrick Contributions to the Mathematical Theory of Epidemics, *Proceeding of the Royal Society of London* **115A** (1927), 700-721. [https://doi.org/10.1016/S0092-8240\(05\)80040-0](https://doi.org/10.1016/S0092-8240(05)80040-0) (reprinted)
- [8] J.F. Medina, M.E. Cortés, M. Cortés, A.C. Pérez, y M. Manzano, Estudio sobre modelos predictivos para la COVID-19 en Cuba, *Medisur* **18**(3) (2020). <http://www.medisur.sld.cu/index.php/medisur/article/view/4703>
- [9] M.A. Villalobos, Estimación de población contagiada por COVID-19 usando regresión Logística generalizada y heurísticas de optimización, *arXiv* (2020). <https://arxiv.org/pdf/2004.01207>
- [10] A. Ahmadi, Y. Fadaei, M. Shirani, y F. Rahmani, Modelling and forecasting trend of COVID-19 epidemic in Iran (preprint), *medRxiv* (2020). <https://doi.org/10.1101/2020.03.17.20037671>
- [11] M. Díaz-Canel, y J. Núñez, Gestión gubernamental y ciencia cubana en el enfrentamiento a la COVID-19, *Anales de la Academia de Ciencias de Cuba* **10**(2) (2020), 199-208. <http://www.revistaccuba.sld.cu/index.php/revacc/article/view/881>
- [12] C. Tsallis, y U. Tirnakli, Predicting COVID-19 peaks around the world, *Frontiers in Physics* **8** (2020), A217. <https://doi.org/10.3389/fphy.2020.00217>
- [13] A.-P. Zahiri, S. RafieeNasab, y E. Roohi, Prediction of peak and termination of novel coronavirus COVID-19 epidemic in Iran (preprint), *medRxiv* (2020). <https://doi.org/10.1101/2020.03.29.20046532>
- [14] T. Benaglia, D. Chauveau, D.R. Hunter, y D. Young, mixtools: An R package for analyzing finite mixture models, *Journal of Statistical Software*, **32**(6) (2009), 1-29. <http://dx.doi.org/10.18637/jss.v032.i06>
- [15] C.B. Do, y S. Batzoglou, What is the expectation maximization algorithm?, *Nature Biotechnology* **26**(8) (2008), 897-899. <https://doi.org/10.1038/nbt1406>
- [16] P. Schlattmann, *Medical Applications of Finite Mixture Models*. Berlin: Springer (2009). <https://doi.org/10.1007/978-3-540-68651-4>
- [17] M. Cruz, *El Método Delphi en las Investigaciones Educativas*. La Habana: Academia, 2009.
- [18] J. Landeta, *El Método Delphi: Una Técnica de Previsión para la Incertidumbre*. Barcelona: Ariel, 1999.
- [19] M.S. Sawhney, et al., Triaging advanced GI endoscopy procedures during the COVID-19 pandemic: consensus recommendations using the Delphi method, *Gastrointestinal Endoscopy* (2020). <https://doi.org/10.1016/j.gie.2020.05.014>
- [20] M. Vitacca, et al., Italian suggestions for pulmonary rehabilitation in COVID-19 patients recovering from acute respiratory failure: results of a Delphi process, *Monaldi Archives for Chest Disease* **90**(2) (2020), 1444. <https://doi.org/10.4081/monaldi.2020.1444>
- [21] F. Eibensteiner, et al., Rapid response in the COVID-19 pandemic: a Delphi study from the European Pediatric Dialysis Working Group, *Pediatric Nephrology* (2020). <https://doi.org/10.1007/s00467-020-04584-6>
- [22] Welsh Surgical Research Initiative (WSRI) Collaborative, Surgery during the COVID-19 pandemic: operating room suggestions from an international Delphi

- process, *British Journal of Surgery*, Early View (2020). <https://doi.org/10.1002/bjs.11747>
- [23] F. Hasson, y S. Keeney, Enhancing rigour in the Delphi technique research, *Technological Forecasting & Social Change* **78**(9) (2011), 1695-1704. <https://doi.org/10.1016/j.techfore.2011.04.005>
- [24] M. Cruz, y J.A. Rúa, Surgimiento y desarrollo del método Delphi: una perspectiva cuantitativa, *Biblios*, **71** (2011), 90-107. <https://doi.org/10.5195/biblios.2018.470>
- [25] D. Li, y D. Yi, *Artificial Intelligence with Uncertainty*. Boca Raton, FL: Chapman & Hall/CRC, 2008. <https://doi.org/10.1109/CIT.2004.1357163>
- [26] T.K. Roy, y A. Garai, Intuitionistic fuzzy Delphi method: more realistic and interactive forecasting tool, *Notes on Intuitionistic Fuzzy Sets*, **12**(2) (2012), 37-50. <http://ifigenia.org/images/0/06/NIFS-18-2-37-50.pdf>
- [27] D. Li, C. Liu, y W. Gan, A new cognitive model: cloud model, *International Journal of Intelligent Systems* **24**(3) (2009), 357-375. <https://doi.org/10.1002/int.20340>
- [28] X.-J. Yang, L. Zeng, y R. Zhang, Cloud Delphi method. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* **20**(1) (2012), 77-97. <https://doi.org/10.1142/S0218488512500055>
- [29] M. Cruz, Una función en R para el método Delphi de Nube. Aplicaciones al pronóstico educacional. Artículo enviado a la revista *Tecnología Educativa* (2020).