



Modelo bayesiano nutricional para el pronóstico de la morbilidad en neonatos.

Bayesian nutritional model for morbidity prognosis in newborns.

Juan J. Soria * , Nemias Saboya † , and Omar L. Loaiza ‡ 

Received, Jul. 21, 2019

Accepted, Nov. 24, 2019



How to cite this article:

Soria, J., et al. *Modelo bayesiano nutricional para el pronóstico de la morbilidad en neonatos*. *Selecciones Matemáticas*. 2019; 6(2):329-337. <http://dx.doi.org/10.17268/sel.mat.2019.02.19>

Resumen

Se ha diseñado esta investigación con el objetivo de formular un modelo bayesiano nutricional para el pronóstico de la morbilidad en neonatos de madres gestantes de Lima Metropolitana. Este modelo está basado en algoritmos de Naive Bayes que consiste en clasificar el aprendizaje automático con variables predictoras independientes entre sí. Asimismo, se ha aplicado algoritmos matemáticos para la exploración de la información respecto a la prevención de posibles problemas relacionados con la salud. Se utilizó 13 variables nutricionales predictoras propuesta por Krauss. La investigación consistió en primer lugar, en la recopilación de la información nutricional de manera controlada de las gestantes involucradas, luego, se analizó la información para determinar la relación de las variables más influyentes, posteriormente se elaboró el modelo bayesiano de característica acíclica y dirigida compuesta por nodos y aristas, porque se conoce que las variables afectan directamente a la morbilidad del neonato y finalmente se validó el modelo considerando los resultados estadísticos de las variables nutricionales, como parte del proceso de formulación del modelo y por juicio de expertos en el tema. En conclusión, las variables predictoras que influyen directamente son: panes, azúcares, aceites, grasas y sal; e indirectamente: frutas, agua, verduras y hortalizas; asimismo el modelo pronostica la morbilidad del neonato con una probabilidad del 92 % y un error del 8.0 %.

Palabras claves. Morbilidad del neonato, redes bayesianas, pronóstico de la morbilidad.

Abstract

This research aimed to formulate a Bayesian model based on the Naive Bayes algorithm, to predict morbidity in neonates in a case study of pregnant mothers in Metropolitan Lima. The study uses mathematical algorithms for the exploitation of information in prevention of possible health-related problems. 13 predictive nutritional variables proposed by Krauss were raised. The model consists first of all, in the collection of the nutritional information in a controlled way of the pregnant women involved, then, the information is analyzed to determine the relationship of the most influential variables for the model, then the Bayesian model of acyclic characteristic was constructed and directed composed of nodes and edges, because the variables directly affected to the morbidity of the neonate are known and finally the model affected by the statistical results of the nutritional variables is validated, as part of the process of formulating the model and by experts judgment in the topic. The results conclude that the predictive variables that directly influence are: breads, sugars, oils, fats and salt; and conversely: fruits, water, vegetables and vegetables; the model also predicts the morbidity of the newborn with a probability of 92% and an error of 8.0%.

Keywords. Newborn morbidity, Bayesian networks, morbidity prognosis.

*Universidad Peruana Unión, Lurigancho-Chosica/Lima Perú. (jesussoria@upeu.edu.pe).

†Universidad Peruana Unión, Lurigancho-Chosica/Lima Perú. (saboya@upeu.edu.pe).

‡Universidad Peruana Unión, Lurigancho-Chosica/Lima Perú. (omarlj@upeu.edu.pe).

1. Introducción. Los temas relacionados con el cuidado de la salud representan una constante preocupación en las políticas de salud de un país, principalmente en los procesos de embarazo y primeros años de la infancia [3]. En respuesta a esta problemática se realizó la investigación con el objetivo de formular un modelo bayesiano nutricional para el pronóstico de la morbilidad en neonatos de madres gestantes de Lima Metropolitana. Este estudio se abordó desde el punto de vista del uso de modelos de inteligencia artificial y tecnologías de la información aplicadas a las ciencias de la salud.

El embarazo, dentro del proceso de reproducción humana se desarrolla en los aspectos físico, neurológico y mental del neonato [1], por esta razón, es importante determinar la morbilidad, para lograr un adecuado estado de salud en las madres gestantes [3].

En un país multicultural como el Perú, con una diversidad geográfica, se ha observado que existen centros públicos de salud alejados de la población beneficiaria [3], carentes de equipados adecuados, esto dificulta el control apropiado de las madres gestantes

En el aspecto nutricional de las madres gestantes [12], un factor de control que se tuvo en cuenta fue el IMC (Índice de Masa Corporal), a través de este análisis se obtuvo datos del control de peso de acuerdo a los meses de gestación para ayudar el desarrollo del feto.

La inferencia estadística bayesiana está basada en el teorema de Bayes para hacer inferencias coherentes sobre la probabilidad de una hipótesis. Los datos observados se incluyen en el proceso de inferencia; con este enfoque la probabilidad cuantifica un estado del conocimiento y representa la probabilidad de un evento donde la verosimilitud implica una validez; es decir, la inferencia bayesiana usa distribuciones de probabilidad para codificar información, donde la métrica es una probabilidad en una escala que varía de 0 hasta 1. El teorema de Bayes proporciona los medios matemáticos para combinar información y datos en el contexto de un modelo probabilístico, con el fin de actualizar un estado previo del conocimiento, donde el teorema modifica una probabilidad previa, produciendo una probabilidad posterior [12].

Las redes bayesianas, como se explicará más adelante, es una técnica de modelamiento útil en el estudio de la relación de las variables independientes [4] en el aspecto nutricional de las madres gestantes y su efecto predictivo en la morbilidad de las mismas.

Los algoritmos de aprendizaje de redes bayesianas se centran en el descubrimiento de relaciones de independencia y relevancia entre variables [6], por lo que el modelo resultante refleja de forma explícita numerosas relaciones de interés. En cierto modo, permiten establecer relaciones relevantes que las reglas de asociación. Su exploración mediante técnicas de inferencia probabilística [14], permitió ampliar el conjunto de relaciones descubiertas y evaluar las distintas hipótesis que se evaluó en este estudio.

En cuanto al uso predictivo, las redes bayesianas se utilizó como clasificador [14]. Para esta tarea, se podrá construir redes con distinto nivel de complejidad mediante la adición de restricciones al proceso de aprendizaje.

Las redes bayesianas, en los últimos años han demostrado su potencialidad como modelo de representación del conocimiento con incertidumbre [5]. Este formalismo nació como una aportación de diferentes campos de la investigación [4]: teoría de toma de decisiones, estadística e inteligencia artificial. Su aporte en numerosas aplicaciones en campos variados [4] como la medicina, la recuperación de información, la visión artificial, la fusión de información, la agricultura, que la avalan en este formalismo.

2. Redes bayesianas. Las redes bayesianas representan el conocimiento cualitativo del modelo mediante grafo dirigidos [4]. como se aprecia en la Figura 2.1. Este conocimiento se articula en la definición de relaciones de independencia/dependencia entre las variables que componen el modelo [8]. Estas relaciones abarcan desde una independencia completa hasta una dependencia funcional entre las variables de un modelo. El hecho de utilizar una representación gráfica para la especificación del modelo hace de las redes bayesianas [15]. una herramienta atractiva por su comprensión y valor de representación del conocimiento.

Las redes bayesianas no solo modelan de forma cualitativa el conocimiento sino que además expresan de forma numérica la “fuerza” de las relaciones entre las variables [4]. Esta parte cuantitativa del modelo suele especificarse mediante distribuciones de probabilidad como una medida de la carencia que tenemos sobre las relaciones entre variables del modelo.

Formalmente, una red bayesiana es un grafo acíclico dirigido y anotado que describe la distribución de probabilidad conjunta que gobierna un conjunto de variables aleatorias. [4].

2.1. Aprendizaje bayesiano . Una red bayesiana, una vez construida, constituye un instrumento potente para el razonamiento probabilístico. Sin embargo, queda la tarea de la construcción de tal modelo. Debido al gran volumen de datos de los que habitualmente se dispone en dominios concretos, es de enorme interés proporcionarles a estos

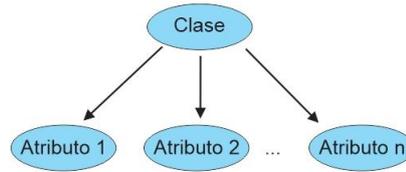


FIGURA 2.1. Representación de relación en un modelo bayesiano

expertos herramientas que adquieran este tipo de conocimiento [6], para que de esta forma se tenga un instrumento de soporte para la decisión.

El problema del aprendizaje de redes bayesianas lo define [4], [14], como un conjunto de datos, cuyo objetivo es encontrar el grafo dirigido acíclico que mejor represente el conjunto de dependencias/independencias presentes en los datos. Para solucionar este aspecto, desde el punto de vista bayesiano, es necesario calcular la probabilidad a posteriori de una red bayesiana dado el conjunto de datos conocidos, esto es, una vez que se conoce cómo calcular esta probabilidad, se tiene una medida de adecuación de cada grafo (red bayesiana) a los datos de partida y por consiguiente se puede comparar, para quedarse con la mejor, entre distintas redes bayesianas.

Cowles, M. [?] menciona que para formular una red bayesiana se deben definir algunas medidas o métricas bayesianas de la optimización de una red bayesiana respecto a datos que le sirven de entrada .

3. Medidas bayesianas. Sea $G=(V,E)$ un grafo dirigido acíclico que representa una red bayesiana , donde V es el conjunto de parámetros definidos en la red, esto es, el conjunto de distribuciones de probabilidad condicional. Sean los casos de datos con la siguiente forma como en la ecuación (3.1):

$$(3.1) \quad D = \begin{pmatrix} I_1[1] & I_2[1] & \dots I_n[1] \\ \vdots & \vdots & \vdots \\ I_1[N] & I_2[N] & \dots I_n[N] \end{pmatrix}$$

El problema consiste en calcular la probabilidad, es decir la probabilidad de una red dados los datos. La regla de Bayes que se aplica como se ve en la ecuación (3.2)

$$(3.2) \quad P(G/D) = \frac{P(D/G)P(G)}{P(D)}$$

Como los datos y constantes son conocidos, entonces el término puede eliminarse de la expresión anterior. Además, una red bayesiana posee dos componentes (parámetros y estructura o grafo) con lo que la expresión anterior se traduce en las ecuaciones (3.3) y (3.4):

$$(3.3) \quad P(G/D) \propto P(G)L(D/G)$$

$$(3.4) \quad L(D/G) = \int_{\Theta} P(D/G, \Theta)P(\Theta/G) d\Theta$$

Siendo $L(D/G)$ la función denominada verosimilitud marginal. Para el caso discreto, asumiendo que las distribuciones son de la familia exponencial y en concreto para el caso multinomial y su conjugada, la formula anterior tiene una solución cerrada dando lugar a una medida bayesiana, como se muestra en la ecuación (3.5):

$$(3.5) \quad L(D/G) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} \prod_{k=1}^{r_1} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}$$

Siendo la función gamma y los hiper parámetros de la distribución a priori. Si estos hiperparámetros se suponen uniformes, entonces los pueden igualarse a una constante, denominada tamaño muestral equivalente. Además, N_{ijk}

es la frecuencia de aparición en los datos de la variable i -ésima con su k -ésimo (de los r_1 posibles) y para la configuración j -ésima (de los q_1 posibles) de sus padres en el grafo. Por último, tanto N_{ijk} como α_{ijk} es igual a su proyección sobre k , esto es: $N_{ij} = \sum_{k=1}^{r_1} N_{ijk}$. Para un estudio más profundo sobre las suposiciones realizadas y los pasos hasta la expresión anterior.

Se ha de destacar que la métrica es descomponible, en el sentido de que se puede calcular de forma local para cada familia (conjunto formado por un nodo y sus padres en G). Por tanto, la métrica podrá expresarse, tomando la función logarítmica como está en la ecuación (3.6):

$$(3.6) \quad f(G : D) = \log L(D/G) = \sum_{i=1}^n f(X_i/Pa(X) : D)$$

Siendo que en la ecuación (3.7):

$$(3.7) \quad f_i(X_i/Pa(X_i) : D) = \sum_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} + \sum_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}$$

Existen otros tipos de medidas de calidad para calcular la adecuación de una red bayesiana a un conjunto de datos. Estas se basan en otros enfoques provenientes de la teoría de la información y del principio de longitud mínima, en donde se utilizan información y del principio de longitud de descripción mínima, en donde se utilizan criterios de máxima verosimilitud para la estimación de los parámetros en una red bayesiana, como por ejemplo la métrica denominada BIC (Bayesian Information Criterion), la cual tiene la siguiente expresión como se ve en la ecuación (3.8):

$$(3.8) \quad f_i(X_i/Pa(X_i) : D) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log\left(\frac{N_{ijk}}{N_{ij}}\right) - \frac{1}{2} \text{Dim}(B) \log N_{ss}$$

Donde representa una función para calcular el número de parámetros libres que se necesitan especificar en una red bayesiana, esto es, (número de entradas independientes en las tablas de probabilidad) y N representa el número total de casos en los datos.

3.1. Morbilidad del neonato. Según [3]. El período neonatal comienza en el nacimiento y termina 28 días completos después del nacimiento. Las muertes neonatales (las muertes entre los nacidos vivos durante los primeros 28 días completos de vida) [1]. pueden subdividirse en muertes neonatales precoces, que ocurren durante los siete primeros días de vida, y muertes neonatales tardías, que ocurren después del séptimo día pero antes de los 28 días completos de vida pronóstico. Así mismo [9]. menciona que se realizó una investigación analítica longitudinal retrospectiva con enfoque mixto en el servicio de neonatología del hospital “Mariana Grajales” desde enero de 2012 hasta julio de 2015 con el objetivo de caracterizar las variables afines con la morbilidad y la mortalidad neonatal en los hijos de madres en edades extremas. La población de estudio la conformaron 69 neonatos enfermos hijos de madres menores de 20 años y mayores de 35. La información obtenida se registró en un formulario que recogió variables maternas y perinatales. Los hijos de madres en edades extremas fueron 1092 neonatos (18.8 %) y prevalecieron los de adolescentes (611, 10.5 %) contra 481 (8.3 %) los de madres añosas; en ambos grupos predominaron los neonatos a término (65.8 %), con peso mayor o igual a 2 500 gramos (63.8 %) y con una distribución por sexo casi equitativa; seis de cada cien hijos de madres en edades extremas se enferman, prevaleció la morbilidad no crítica (75.1 %) y la hiperbilirrubinemia fue la enfermedad clínica más frecuente. No se evidenció asociación entre las edades maternas extremas y la morbilidad neonatal; ser hijo de madre adolescente o añosa no constituyó un riesgo para morir en la población estudiada.

Según [13]. menciona que el objetivo de la investigación fue identificar eventos perinatales en partos pretérmino con recién nacidos menores de 1500 g. en la cual se aplicó un estudio descriptivo de 80 gestantes con edad gestacional entre 28.0 y 36.6 semanas que presentaron partos pretérmino con recién nacidos menores de 1500 gramos pertenecientes al Hospital Ginecobstétrico Ramón González Coro, desde enero de 2008 a diciembre de 2010. El análisis descriptivo de los datos se realizó mediante distribuciones de frecuencias absolutas y relativas. Se utilizó la prueba Chi Cuadrado (X^2) con un 95 % de confiabilidad cuyos resultados fueron que el 75 % presentó factores de riesgo en la que predominaron los trastornos hipertensivos del embarazo, el asma bronquial y la anemia con un 48.8 %, 7.5 % y 6.3 % respectivamente. El 45 % de los partos fue secundario a una rotura prematura de membranas pretérmino. El

bajo peso al nacer predominó en el 56.3 % del total. El 29.8 % presentó restricción del crecimiento fetal y el 28.6 % enfermedad de membrana hialina.

Además [7], menciona que su modelo predictivo de neonatos de un total de 304 recién nacidos que se inscribieron en el estudio, 94 (30.1 %) tuvieron pesos al nacer de menos de 2.5 kg en la que la mediana de la gestación fue de 39 semanas (IQR: 37-40) y la mediana de la temperatura corporal fue de 37,9°C (IQR: 37 – 38,2°C) y un total de 57 (14.1 %) de todos los neonatos fueron partos por cesáreas y 16 (5.3 %) fueron entregados en casa.

3.1.1. Descripción del método. En esta sección se describe el desarrollo del trabajo y puede contener varias sub-secciones con títulos específicos, y numerados en forma consecutiva de acuerdo al contenido. Cabe destacar que el acercamiento de la investigación es desde el ángulo de la inteligencia artificial y las tecnologías de la información. En la primera etapa, se efectuó el reconocimiento de las variables que deberían intervenir en el estudio con sus valores máximos y mínimos permitidos los que se compararon con los niveles consumidos por las madres para conocer rangos bajos, medios y altos de consumo. Luego en la segunda etapa, se recolectaron los datos de las variables registrando el consumo de alimentos del grupo piloto de gestantes participantes. Posteriormente en la tercera etapa, se diseñó el modelo bayesiano con tres sub-etapas: a) se calcularon las probabilidades de ocurrencia de cada variable en tres rangos: alto, medio y bajo, referido al nivel de consumo bajo, medio y alto; b) se validó la correlación de cada variable con el estadístico de Rho de Spearman y c) se diagramó la dirección de relación cada variable respecto a la variable morbilidad del neonato en el programa Netica, configurando los niveles (alto, medio y bajo). Finalmente, se validaron los resultados a través de juicio de expertos y con pruebas manuales para dar consistencia y validez al modelo bayesiano nutricional. En la Figura 3.1 se aprecia la secuencia de fases ejecutada en la investigación.

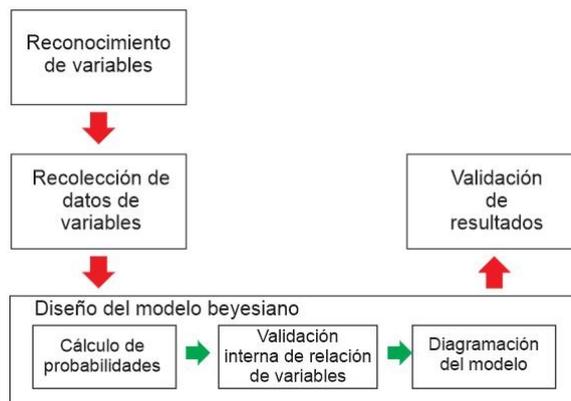


FIGURA 3.1. Secuencia de actividades de la investigación

[6] menciona que la validación del modelo bayesiano con estadísticas Bayesiana Chi Cuadrada de resumen de distribución predictiva posterior se usa los valores observados de X para formar la igualdad $\chi_{obs}^2 = \sum_i \frac{(X_{obs,i} - \mu_i)^2}{\sigma_i^2}$ Para luego generar valores pronosticados X a partir de su distribución predictiva posterior y construir la ecuación $\chi_{rep}^2 = \sum_i \frac{(X_{pre,i} - \mu_i)^2}{\sigma_i^2}$

3.1. Reconocimiento de las variables

Se trabajó inicialmente con el reconocimiento de las variables en función a lo mencionado por Raymond. J. & Mahan. K. [11], que son: cereales, panes, verduras y hortalizas, frutas, aceites y grasas, productos lácteos, carnes, legumbres y huevos, complementos vitamínicos, agua, descalcificantes, sal, azúcar y condimentos. Cada una de las categorías antes mencionadas posee un valor máximo y un valor mínimo de consumo [11], dichos valores fueron obtenidos mediante la agrupación de los alimentos de acuerdo a la pirámide alimenticia. Se consideró la cantidad de calorías que aportaba cada grupo en base a una ración de 100g todos considerados en consumos diarios. Estos valores son comparados con el total de las porciones consumidas por la madre gestante con la intención de medir su nivel de consumo. Se debe considerar normal cuando el consumo total diario está dentro de los límites establecidos; bajo, cuando el consumo total diario es menor a lo establecido; y, en exceso, cuando el consumo es superior.

3.2 Recolección de datos de las variables Concluida el reconocimiento de las variables se recolectó la información de un grupo de madres gestantes durante un tiempo determinado con el apoyo de especialistas utilizando una ficha de registro donde contemplaba todas las variables en estudio, posteriormente se elaboró la data respectiva validando cada información de las mismas.

3.3. Diseño del modelo bayesiano

Posteriormente se calculó la probabilidad de cada uno de las categorías, con información de la cantidad de raciones que la madre consumió durante los días del experimento, comparadas con las cantidades permitidas según categorías las cuales se muestran en la siguiente tabla 1:

Tabla 1. Cantidades permitidas por dimensión nutricional

| Dimensión | Des De | Hasta | x 14 días | x 14 días | ΣRaciones | Probabilidad |
|----------------------------|--------|-------|-----------|-----------|--------------|--------------|
| Cereales | 400 | 420 | 5600 | 5880 | 5880 | 0.281 |
| Panes | 2 | 3 | 28 | 42 | 25 | 0.001 |
| Verduras y hortalizas | 400 | 420 | 5600 | 5680 | 8190 | 0.391 |
| Frutas | 4 | 5 | 56 | 70 | 59 | 0.003 |
| Aceites y grasas | 0 | 1 | 0 | 14 | 76 | 0.004 |
| Productos lácteos | 400 | 420 | 5600 | 5680 | 2100 | 0.100 |
| Carnes, legumbres y huevos | 200 | 300 | 2800 | 4200 | 3300 | 0.158 |
| Complementos vitamínicos | 1 | 2 | 14 | 28 | 11 | 0.001 |
| Agua | 7 | 8 | 98 | 112 | 90 | 0.004 |
| Descalcificantes | 0 | 0 | 0 | 0 | 700 | 0.033 |
| Sal | 0 | 4 | 0 | 56 | 116 | 0.006 |
| Azúcar | 0 | 24 | 0 | 336 | 312 | 0.015 |
| Condimentos | 0 | 4 | 0 | 56 | 68 | 0.003 |
| Total | | | | | 20927 | 1.000 |

Una vez obtenida la probabilidad de cada una de las categorías, se evaluó las categorías en función si sobrepasa o no el rango permitido. Considerando que cada una de las categorías tienen un valor de cuanto afecta a la morbilidad en caso exista un bajo o exceso consumo. El resultado de este análisis de una madre se muestra en la tabla 2.

Tabla 2. Consumo por debajo y de exceso por dimensión nutricional

| Dimensión | Bajo | Exceso |
|--------------------------|------|--------|
| Aceites y grasas | 0.01 | 1.00 |
| Azúcar | 0.02 | 1.00 |
| Agua | 0.70 | 0.70 |
| Carnes y legumbres | 0.50 | 1.00 |
| Cereales | 0.55 | 0.25 |
| Complementos vitamínicos | 0.40 | 1.00 |
| Condimentos | 0.00 | 1.00 |
| Descalcificantes | 0.00 | 1.00 |
| Frutas | 0.55 | 0.25 |
| Panes | 0.02 | 1.00 |
| Lácteos | 0.60 | 0.30 |
| Sal | 0.00 | 1.00 |
| Verduras y hortalizas | 0.55 | 0.25 |

3.4. Validación interna de la relación de variables

Para que las variables sean consideradas en el modelo bayesiano nutricional, fue necesario determinar sus correlaciones a través de un análisis estadístico y ver su intensidad entre ellas, el detalle se explica a continuación. La Tabla 3 evidencia que todas las variables analizadas tienen una intensidad considerable en sus relaciones con p-value < 0.05. Es importante resaltar que las variables más significativa respecto a la morbilidad son en el siguiente orden: panes con $r=0.939$, azúcar con $r=0.70$, aceites y grasas con $r=0.679$ y sal con $r=0.641$. Por otro lado, aquellas variables existen algunas variables que se relacionan inversamente, esto quiere decir que, a menor consumo de un elemento nutricional mayor probabilidad de morbilidad y viceversa, en este grupo tenemos: agua con $r=-0.694$, frutas con $r=-0.523$ y finalmente verduras y hortalizas con un $r=-0.551$.

3.5. Diagramación del modelo

El diagrama bayesiano fue elaborado en el programa Netica una vez validadas las variables consideradas en el estudio.

Tabla 3. Correlaciones de variables participantes en el modelo

| Dimensión | Correlac. Spearman | Sig Bilateral | Existe correlación |
|--------------------------|--------------------|---------------|--------------------|
| Aceites y grasas | 0.679 | 0.008 | Si |
| Azúcar | 0.700 | 0.010 | Si |
| Agua | -0.694 | 0.043 | Si |
| Carnes y legumbres | 0.475 | 0.046 | Si |
| Cereales | 0.505 | 0.047 | Si |
| Complementos vitamínicos | 0.452 | 0.042 | Si |
| Condimentos | 0.399 | 0.049 | Si |
| Descalcificación | 0.547 | 0.045 | Si |
| Frutas | -0.523 | 0.048 | Si |
| Panes | 0.939 | 0.003 | Si |
| Lácteos | -0.402 | 0.044 | Si |
| Sal | 0.641 | 0.013 | Si |
| Verduras y hortalizas | -0.551 | 0.041 | Si |

En la figura 3.2 se visualiza el sentido y comportamiento de cada una de las variables en el modelo, y como estas afectan directa e inversamente en la probabilidad de la morbilidad del neonato.

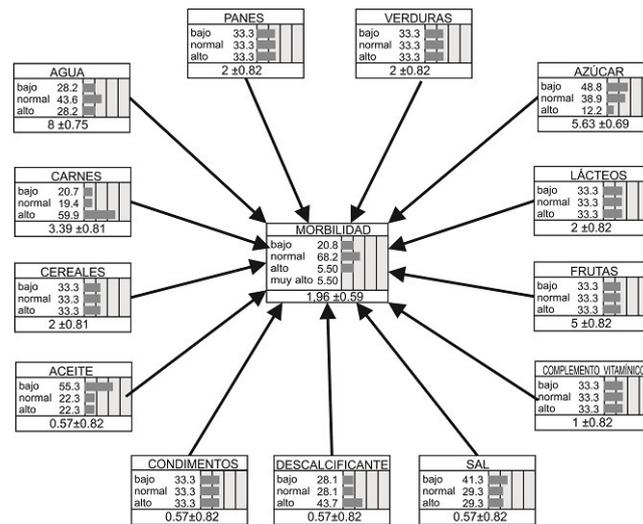


FIGURA 3.2. Diagrama bayesiano del modelo nutricional

Finalmente, una vez obtenido todos los valores según las categorías se aplicó la fórmula de Bayes en el modelo, y se consideró agregar el riesgo en cuanto a la edad de la madre (34 años) y su índice de masa corporal. Se tuvo como valor final de: 0.92 que representa el 92 %

Existe un modelo estadístico [10].

$$(3.9) \quad R_{c,t} = \frac{N_{c,t}}{U_{c,t} - N_{c,t}}$$

que se refiere a la proporción real de muertes neonatales en comparación con las muertes en los meses de 1 a 9. Con la restricción $R_{c,t} > 0$ en la ecuación (3.9)

$$(3.10) \quad 0 \leq \frac{N_{c,t}}{U_{c,t}} \leq 1$$

donde la verdadera proporción es $R_{c,t} = f(U_{c,t}) \cdot P_{c,t}$ donde $f(U_{c,t})$ es el índice esperado general dado el nivel actual.

Según [2], para modelar la proporción de muertes neonatales y no neonatales se encontró una función $f(U_{c,t})$ el cual se modeló con la siguiente relación de la ecuación (3.11) & (3.12):

$$(3.11) \quad \text{Log}[f(U_{c,t})] = \{\beta_0; U_{c,t} \leq 0\}$$

$$(3.12) \quad \text{Log}[f(U_{c,t})] = \{\beta_0 + \beta_1 \text{Log}(U_{c,t} - \text{Log}(\theta)); U_{c,t} > 0\}$$

En la investigación el modelo bayesiano fue más efectivo ya que al usar la prueba estadística del Chi cuadrado Bayesiano se encontró que las variables nutricionales que más han influenciado directamente afectando a madres son los panes con un $\rho = 0,939$, así mismo el azúcar con un $\rho = 0,70$, la sal con un $\rho = 0,641$ y los aceites y grasas. Por lo tanto el modelo bayesiano formulado en el estudio es significativo porque su importancia benefició a las madres gestantes con una nutrición balanceada y adecuada con la finalidad de que el neonato probabilísticamente no tenga daños como menciona Odalis, D. [9]. El modelo en estudio se validó con el estadístico Chi cuadrado predictiva bayesiana el cual se alcanzó un 92 % de predicción.

4. Conclusiones. El estudio concluye que el modelo bayesiano nutricional, aplicado a un conjunto piloto de madres, con una robustez de chi cuadrado predictivo bayesiano, ayudó al pronóstico de la morbilidad del neonato en gestantes con una probabilidad considerable del 92 %. En relación a la consistencia interna del modelo bayesiano se encontró que las variables directas fueron: panes, azúcar, aceites, grasas y sal, estos afectan directamente al pronóstico de la morbilidad del neonato; sin embargo, las variables indirectas que afectan fueron: las frutas, agua, verduras y hortalizas.

5. Agradecimiento. Se agradece equipo de investigadores que aportaron en la investigación así como a los estudiantes Miguel A. Chacón y Néstor Ocaña S.

ORCID and License

Soria Quijaite Juan Jesús <https://orcid.org/0000-0002-4415-8622>,

Saboya Rios Nemias <https://orcid.org/0000-0002-7166-2197>,

Loiza Jara Omar Leonel <https://orcid.org/0000-0002-3262-709X>.

This work is licensed under the [Creative Commons Attribution-NoComercial-ShareAlike 4.0](https://creativecommons.org/licenses/by-nc-sa/4.0/).

Referencias

- [1] Almira, A.G. Embarazo: diagnóstico, edad gestacional, y fecha del parto. MEDISAN. 2008; 12(4):10. <https://www.redalyc.org/pdf/3684/368445249017.pdf>.
- [2] Alexander, M., & Alkema, L. Global estimation of neonatal mortality using a Bayesian hierarchical splines regression model. Demographic Research. 2018; 38(1):335–372. <https://www.demographic-research.org/volumes/vol38/15/>.
- [3] Avila J. & Machuca V. Mortalidad en el Perú y sus departamentos. Dirección General de Epidemiología- Ministerio de Salud. 2013. http://www.dge.gob.pe/portal/docs/Mortalidad_neonatal11_12.pdf.
- [4] Gamez, A., Moral, S., & Salmerón. A. Advances in Bayesian Networks. Studies in Fuzziness and Soft Computing. 2004; Volume 146: . DOI10.1007/978-3-540-39879-0.
- [5] Holmes D. & Jain L. Innovations in Bayesian Networks. Theory and Applications, University of California, 2008; , Volume 156: . DOI10.1007/978-3-540-85066-3.
- [6] Kelly, D., & Smith, C. Advanced Methodologies for Bayesian Networks (Vol. 9505). Springer London. New York, 2011. DOI10.1007/978-1-84996-187-5.
- [7] Marando, R., Seni, J., Mirambo, M. M., Falgenhauer, L., Moremi, N., Mushi, M. F., Mshana, S. E. Predictors of the extended-spectrum-beta lactamases producing Enterobacteriaceae neonatal sepsis at a tertiary hospital, Tanzania. International Journal of Medical Microbiology. 2018; 308(7):803–811. <https://doi.org/10.1016/j.ijmm.2018.06.012>.
- [8] Nagarajan, R., Scutari, M. Bayesian networks in R with applications in systems biology. Springer. New York, 2013. DOI10.1007/978-1-4614-6446-4.
- [9] Odalis, D., Caridad, D., Milián, A., Yamila, D., Caraballo, S., & Orlando, R. Morbilidad y mortalidad en hijos de madres en edades extremas. INFOMED. 2016; 10(4):27–35. <http://www.revactamedicacentro.sld.cu/index.php/amc/article/view/760/1004>.
- [10] Olpo. A. , Louazda. F., Rifo. L., Stern. J. & Lauretto. M. Interdisciplinary Bayesian Statistics. Springer Heidelberg. 2015. 10.1007/978-3-319-12454-4.
- [11] Raymond. J. & Mahan. K. Krauses Food & the Nutrition Care Process. Elsevier Inc. All Rights Reserved. Barcelona, España. 2017.

- [12] Ross C. & Taylor C. DIETARY REFERENCE INTAKES. Calcium Vitamin D. Institute of Medicine. of the National Academies, 2011. https://www.ncbi.nlm.nih.gov/books/NBK56070/pdf/Bookshelf_NBK56070.pdf.
- [13] Sanabria, A., Nodarse, A., Carrillo, L., y Couret, M., Sánchez & N.; Guzmán, R. Morbilidad en el recién nacido menor de 1 500 g. Revista Cubana de Obstetricia y Ginecología. 2012; 38(4):478-487. <http://scielo.sld.cu/pdf/gin/v38n4/gin05412.pdf>.
- [14] Suzuki J. & Ueno M. Advanced Methodologies for Bayesian Networks. Second International Workshop, AMBN 2015. Springer Yokohama, Japan.2015; 16–18, Proceedings. DOI10.1007/978-3-319-28379-1.
- [15] Xu, Y., Choi, J., Dass, S., & Maiti, T. Bayesian Prediction and Adaptive Sampling Algorithms for Mobile Sensor Networks: Online Environmental Field Reconstruction in Space and Time. Springer. Cham Heidelberg, 2016. DOI10.1007/978-3-319-21921-9.