

## Comparação de modelo Clássico e Bayesiano para dados de óbitos perinatais no ISEA, Campina Grande-PB

Sandro L. Lucena<sup>1</sup>, Rafaela S. Vitorino<sup>1†</sup>, Kleber N. N. O. Barros<sup>1</sup>, Márcio A. Albuquerque<sup>1</sup>

<sup>1</sup>Universidade Estadual da Paraíba (UEPB) - Departamento de Estatística (DE) - Centro de Ciências e Tecnologia (CCT) - Campina Grande (CG).

**Resumo:** Modelos lineares generalizados são úteis, dentre outras situações, quando se quer ajustar modelos a dados que não seguem normalidade e não podem ser ajustados usando apenas a regressão linear simples. Outra ferramenta poderosa de estimação são os métodos Bayesianos, baseado em probabilidades condicionais. Neste trabalho apresenta-se um ajuste de modelos de regressão logístico com parâmetros estimado pelo método da máxima verossimilhança que é atualizado usando as técnicas da inferência Bayesiana. Tais métodos foram aplicados em dados obtidos no Instituto de Saúde Elpídio de Almeida que fica localizado no município de Campina Grande - PB. As informações referem-se a pacientes gestantes atendidas nesta unidade de saúde. Objetivou-se obter o melhor modelo possível que nos forneça informação sobre a chance de óbito de uma criança em função de variáveis maternas usando o método de estimação da máxima verossimilhança e o método Bayesiano. Os ajustes e diagnósticos dos modelos foram realizados com auxílio do software R.

**Palavras-chave:** Regressão Logística, Inferência Bayesiana, Óbito Perinatal.

**Abstract:** Generalized linear models are useful, among other situations, when you want to fit models to data that do not follow normality and can not be adjusted using only simple linear regression. Another powerful tool for estimation is Bayesian methods, based on conditional probabilities. In this work we present an adjustment of logistic regression models with parameters estimated by the maximum likelihood method that is updated using Bayesian inference techniques. These methods were applied to the data selected at the Instituto de Saúde Elpídio de Almenida which is located in the city of Campina Grande - PB. The information refers to pregnant patients that attended this health unit. he objective was to obtain the best possible model provide us with information about a child's chance of dying in function of maternal variables using the maximum likelihood estimation method and the Bayesian method. The adjustments and diagnoses of the models were carried out using the software R.

**Keywords:** Logistic Regression, Bayesian Inference, Perinatal death.

## Introdução

A saúde infantil no Brasil vem apresentando avanços importantes principalmente a partir da década de 1990 e 2000, demonstrada por indicadores que mostram significativas melhorias nos determinantes sociais das doenças em conjunto a organização dos serviços de saúde (VICTORA, 2011). Esses avanços são promovidos, em parte, por estudos científicos que podem detectar resultados e oferecer possíveis soluções para problemas que a saúde pública venha a enfrentar.

---

<sup>†</sup>Autora correspondente: [rafaellla\\_17@yahoo.com.br](mailto:rafaellla_17@yahoo.com.br).

Dentre os avanços científicos destacamos o desenvolvimento dos Modelos Lineares Generalizados (MLG's). Estes modelos foram propostos por Nelder e Baker (1972) e apresentam uma componente sistemática, uma componente aleatória e uma função de ligação. Trabalha-se com o modelo logístico, que é um caso especial de modelo linear generalizado quando tem-se a função de probabilidade binomial para a variável resposta e a função de ligação *logit*. O modelo logístico é utilizado quando se tem variável resposta do tipo binária, por isso o uso da função binomial.

Dois métodos foram utilizados para estimar os parâmetros do modelo, o método da máxima verossimilhança, ver Mardia e Marshall (1984), e o método Bayesiano. Para método da máxima verossimilhança a seleção das variáveis é feita pelo método *stepwise* que baseia-se na observação de que uma variável pode ser movida de um conjunto de variáveis para outro conjunto de variáveis que dá maior redução no resíduo.

A adequação do modelo pode ser verificada por meio de vários critérios. O Critério de Informação de Akaike e o desvio residual pode ser utilizado para verificar o quão bom é o modelo ajustado pelo método da máxima verossimilhança e por meio da análise residual verifica-se a adequabilidade do modelo estimado. Para Moral, Hinde e Demétrio (2017), o estudo residual pode ser feito diretamente observando o envelope simulado dos resíduos.

Os métodos bayesianos foram desenvolvidos a partir do trabalho de Thomas Bayes (1702-1761), ministro presbiteriano inglês cujos escritos matemáticos lhe valeram um lugar como membro da Royal Society of London (PICHE; PENTTINEN, 2010). Na abordagem Bayesiana, assume-se que os parâmetros sobre os quais se deseja realizar inferências estão associados a uma distribuição de probabilidade, sendo a distribuição dos mesmos definidas utilizando as informações adicionais que se possa ter sobre as quantidades de interesse ou de estudos anteriores da população estudada (FONSECA; MARTINS, 1996).

## Metodologia e Métodos

O objetivo deste trabalho é obter o melhor modelo logístico que nos forneça informação sobre a chance de óbito de uma criança em função de variáveis maternas usando o método de estimação da máxima verossimilhança e o método bayesiano e compará-los. Os dados foram coletados no Instituto de Saúde Elpidio de Almeida e referem-se a características de gestantes atendidas na maternidade no ano de 2013. Obtemos uma amostra de 2807 mulheres que foram atendidas nesta instituição das quais foram verificados a situação conjugal, o grau de instrução, a raça, a idade, o número de gestações e também verificado se o produto de sua gestação atual veio a óbito. A análise dos dados e a estruturação dos modelos foram realizadas com o auxílio do software R. A análise Bayesiana foi realizada pelo software OpenBUGS.

Os Modelos Lineares Generalizados foram propostos por Nelder e Baker (1972) e apresentam duas componentes: uma aleatória e outra sistemática (Clarice 1989).

Cordeiro e Demétrio (2008) ressaltam que para uma amostra de  $n$  observações  $(y_i, x_i)$  em que  $\mathbf{X}_i = (x_{i1}, \dots, x_{ip})^T$  é o vetor de variáveis explicativas, o MLG envolve os três componentes: componente aleatório, o componente sistemático e a função de ligação.

O componente aleatório representado por um conjunto de variáveis aleatórias independentes  $Y_1, \dots, Y_n$  provenientes de uma mesma distribuição que faz parte da família exponencial de distribuições com média  $\mu_1, \dots, \mu_n$  ou seja,  $E(Y_i) = \mu_i, i = 1, \dots, n$ , sendo  $\phi > 0$  um parâmetro de dispersão e o parâmetros  $\theta_i$  denominado parâmetro canônico. Então, a função densidade de probabilidade de  $Y_i$  é dada por

$$f(y_i, \theta_i, \phi) = \exp\{\phi^{-1}[y_i\theta_i - b(\theta_i)] + c(y_i, \phi)\}, \quad (1)$$

sendo  $b(\cdot)$  e  $c(\cdot)$  funções conhecidas (CORDEIRO; DEMÉTRIO, 2008).

Segundo Paula (2004), sob as condições usuais de regularidade que  $E\left\{\frac{\partial \log f(Y_i; \theta_i, \phi)}{\partial \theta_i}\right\} = 0$  e  $E\left\{\frac{\partial^2 \log f(Y_i; \theta_i, \phi)}{\partial \theta_i^2}\right\} = -E\left[\left\{\frac{\partial \log f(Y_i; \theta_i, \phi)}{\partial \theta_i}\right\}^2\right]$ ,  $\forall_i$ , de onde segue que  $E(Y_i) = \mu_i = b'(\theta_i)$  e

$Var(Y_i) = \phi^{-1}V(\mu_i)$ , em que  $V_i = V(\mu_i) = d\mu_i/d\theta_i$  é a função de variância e  $\phi^{-1} > 0$  é o parâmetro de dispersão.

Paula (2004) ainda comenta que os modelos lineares generalizados definidos por (1) precisam ainda ter um componente sistemático  $g(\mu_i) = \eta_i = \mathbf{X}^T \beta$  sendo  $\eta_i = \mathbf{X}^T \beta$  é o preditor linear,  $\beta = (\beta_1, \dots, \beta_p)^T$ ,  $p < n$ , é um vetor de parâmetros desconhecidos a serem estimados,  $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})$ , representa os valores de variáveis explicativas e  $g(\cdot)$  é uma função monótona e diferenciável, denominada função de ligação (PAULA, 2004).

O modelo binomial é usado, principalmente, no estudo de dados na forma de proporções, como nos casos da análise probito (Finney, 1952), logística (ou "logit") (Ashton, 1972) e complemento log-log (Fisher, 1922), e na análise de dados binários, como na regressão logística linear (Cox, 1970; CORDEIRO; DEMÉTRIO, 2008).

Para Bolfarine e Sandoval (2001), uma variável aleatória  $Y$  tem distribuição binomial, com parâmetros  $n$  e  $\theta$ , que denotamos por  $Y \sim Binomial(n, \theta)$ , se sua função de probabilidade é dada por

$$f(y | \theta) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}, y = 0, 1, \dots, n, \quad (2)$$

em que  $0 < \theta < 1$ . Nesse caso o suporte é discreto e é dado por  $A(y) = \{y, y = 0, 1, \dots, n\}$  Temos também que  $E[Y] = n\theta$  e  $Var[Y] = n\theta(1 - \theta)$ .

Cordeiro e Paula (1989) consideram o modelo logístico linear simples derivado da função matemática  $f(x) = (1 + e^{-x})^{-1}$ ,  $-\infty < x < \infty$  que varia monotonicamente de 0 a 1 à medida que  $x$  cresce, sendo simétrica em torno de  $x = f^{-1}(1/2)$ . O termo linear refere-se à propriedade da transformação logit em  $f(x)$   $\text{logit}f(x) = \log \left[ \frac{f(x)}{1-f(x)} \right] = x$  que é linear em  $x$ . Então tem-se o modelo de regressão logístico linear para prever a probabilidade  $\pi(x) = P\{y = 1|x\}$ . Esse modelo é dado por  $\text{logit}\pi(x) = \eta$  ou

$$\begin{aligned} \pi(x) &= \exp(\eta) / \{1 + \exp(\eta)\} \\ &= \{1 + \exp(-\eta)\}^{-1}, \end{aligned}$$

em que  $\eta = \alpha + \beta x$  é chamado de preditor linear e  $\alpha$  e  $\beta$  são parâmetros a serem estimados (CORDEIRO, PAULA, 1989).

Na maioria dos problemas, no entanto, a variável resposta  $y$  é expressa em função de um grande conjunto de informações, faz-se necessário então um ajuste de múltiplas variáveis regressoras.

Segundo Kinas e Andrade (2010), quando a variável  $y$  é discreta e segue uma distribuição Binomial, então o MLG é denominado regressão logística. As três equações que definem este modelo são definidas a seguir:

$$\begin{aligned} y_i &\sim Bin(n_i, \theta_i) \\ \eta_i &= g(\theta_i) = \log \left( \frac{\theta_i}{1 - \theta_i} \right) \\ \eta_i &= \beta_0 + \beta_1 x_i \end{aligned}$$

A função de ligação definida acima é denominada de função logit e transforma o parâmetro  $\theta$ , restrito ao intervalo  $[0, 1]$ , para  $\eta$  que está definido em  $\mathbb{R}$  (KINAS; ANDRADE, 2010).

A Inferência Bayesiana é baseada em probabilidades subjetivas ou credibilidades a posteriori associadas com diferentes valores do parâmetro  $\theta$  e condicionadas pelo particular valor de  $x$  observado (PAULINO; TURKMAN; MURTEIRA, 2003). O valor de  $x$  é dado, fixado, enquanto que há uma considerada variação no valor de  $\theta$ .

Ainda segundo Paulino, Turkman e Murteira (2003), para os bayesianos há apenas um estimador que é precisamente a distribuição a posteriori  $p(\theta|x)$ .

A informação a priori quantifica a credibilidade que o pesquisador e/ou o estatístico tem diante das informações a respeito de  $\theta$  antes dos acontecimentos. A informação a priori que se pretende incorporar na análise é a informação apriorística possuída por alguém, que se identifica como especialista (perito, expert) do problema concreto - seja ele o investigador, o estatístico ou outrem - e contém elementos subjetivos que, em geral, até são dominantes. A informação a priori pode traduzir-se formalmente por uma distribuição de probabilidade, geralmente subjetiva, para  $\theta$ , seja  $p(\theta)$ , designada distribuição a priori (PAULINO; TURKMAN; MURTEIRA, 2003).

A posteriori de  $\theta$  é a distribuição do parâmetro depois de já ter sabido o resultado dos valores da amostra. Assim tendo em conta as informações contida nos dados y a atitude inicial do investigador, caracterizada por  $p(\theta)$ , é modificada passando a nova atitude a traduzir-se por  $p(\theta|y)$ . Usando o Teorema de Bayes para atualizar a informação a priori, temos:

$$p(\theta|y) = \frac{p(y|\theta)p(\theta)}{\int_{\Theta} p(y|\theta)p(\theta)d\theta},$$

em que  $p(\theta|y)$  é a distribuição a posteriori de  $\theta$  após o conhecimento que já aconteceu  $Y = y$  (PAULINO; TURKMAN; MURTEIRA, 2003).

Quanto à qualidade do modelo, para Nelder e Baker (1972), a função de desvio é mais diretamente útil, não como uma medida absoluta da adequação do ajuste, mas para comparar dois modelos e é definido como sendo o dobro da diferença entre a máxima verossimilhança alcançável e a obtida no modelo ajustado. A função desvio é escrita da forma

$$\begin{aligned} D(y; \hat{\theta}) &= 2l(\mu; y) - 2l(\hat{\mu}; y) \\ &= \sum_i \left\{ y_i \log(y_i/\hat{\mu}_i) + (m_i - y_i) \log\left(\frac{m_i - y_i}{m_i - \hat{\mu}_i}\right) \right\} \end{aligned}$$

A qualidade do ajuste de um MLG é avaliada através da função desvio que é a distância entre o logaritmo da função de verossimilhança do modelo saturado (com  $n$  parâmetros) e do modelo sob investigação (com  $p$  parâmetros) avaliado na estimativa de máxima verossimilhança  $\beta$  (PAULA, 2004). Menores valores para a função desvio indica que obtemos um melhor ajuste. Vale lembrar que a escolha do modelo definitivo depende de outros critérios que podem estar implícitos nos objetivos da pesquisa.

Paula (2004) cita que para o caso Binomial em que assumimos  $Y \sim B(n_i, \mu_i)$ ,  $i = 1, 2, \dots, k$ ,  $\tilde{\theta}_i = \log\{y_i/(n_i - y_i)\}$  e  $\hat{\theta}_i = \log\{\hat{\mu}_i/(1 - \hat{\mu}_i)\}$  para  $0 < y_i < n_i$ , o desvio assume a seguinte forma:

$$D(y; \hat{\mu}) = 2 \sum_{i=1}^k [y_i \log(y_i/n_i \hat{\mu}_i) + (n_i - y_i) \log\{(1 - y_i/n_i)/(1 - \hat{\mu}_i)\}]$$

## Aplicação e Discussão

Dos 2807 prontuários que compõem este estudo, 30,96% ( $IC_{95\%} = [29, 25\%; 32, 67\%]$ ) das mães sofreram com o óbito de pelo menos um produto de sua(s) gestação(ões), enquanto que 69,04% ( $IC_{95\%} = [67, 33\%; 70, 75\%]$ ) não registraram óbitos conforme observado na Tabela 1. Avaliando por variável, no tocante à situação conjugal das mães, há prevalência das solteiras, com percentual de 55,51% ( $IC_{95\%} = [53, 67\%; 57, 35\%]$ ), seguido de mães casadas com 26,00% ( $IC_{95\%} = [24, 38\%; 27, 62\%]$ ) na (Tabela 1). Das 1558 mães solteiras, 29,97% ( $IC_{95\%} = [27, 69\%; 32, 24\%]$ ) tiveram pelo menos um insucesso em alguma de sua(s) gravidez. 50% dos produtos gerados pelas mulheres viúvas vieram a óbito (Tabela 1).

A frequência, segundo o grau de instrução, foi maior para as mulheres que possuem apenas o Ensino Fundamental II com 1167 mães. Em segundo lugar registrou-se mãe com Ensino Médio,

Tabela 1: Número de mães atendidas no ISEA segundo a situação conjugal, o grau de instrução, raça e grupo de idade em 2013.

	Óbito		Total	Teste Qui-Quadrado
	Não	Sim		
	<i>n</i> (%)	<i>n</i> (%)	<i>N</i> (%)	Valor p
<b>Situação Conjugal</b>				0,367
Solteira	1091 (38,87)	467 (16,64)	1558 (55,51)	
Casada	498 (17,74)	232 (8,26)	730 (26,00)	
Viúva	5 (0,18)	5 (0,18)	10 (0,36)	
Divorciada	7 (0,25)	6 (0,21)	13 (0,46)	
União Estável	337 (12,01)	159 (5,66)	496 (17,67)	
<b>Grau de Instrução</b>				0,018
Sem Escolaridade	25 (0,89)	20 (0,71)	45 (1,61)	
Fundamental I	430 (15,32)	225 (8,02)	655 (23,33)	
Fundamental II	815 (29,03)	352 (12,54)	1167 (41,57)	
Ensino Médio	590 (21,02)	249 (8,87)	839 (29,89)	
Superior Incompleto	31 (1,10)	5 (0,18)	36 (1,28)	
Superior Completo	47 (1,67)	18 (0,64)	65 (2,32)	
<b>Raça</b>				0,324
Branca	112 (3,99)	39 (1,39)	151 (5,38)	
Preta	22 (0,78)	14 (0,50)	36 (1,28)	
Parda	1803 (64,23)	816 (29,07)	2619 (93,30)	
Indígena	1 (0,04)	0 (0,00)	1 (0,04)	
<b>Faixa Etária</b>				0,001
[13 – 22]	477 (16,99)	190 (6,77)	667 (23,76)	
[23 – 27]	593 (21,13)	221 (7,87)	814 (29,00)	
[28 – 31]	365 (13,00)	192 (6,84)	557 (19,84)	
[32 – 50]	503 (17,92)	266 (9,48)	769 (27,40)	
<b>Total</b>	1938 (69,04)	869 (30,96)	2807 (100,00)	

com frequência de 590 mães, e em terceiro lugar 430 mães com Ensino Fundamental I (Tabela 1). Constatou-se ainda 1,61% ( $IC_{95\%} = [1, 14\%; 2, 07\%]$ ) das mães não possuem escolaridade. Dessas 44,44% ( $IC_{95\%} = [29, 92\%; 58, 96\%]$ ) perderam pelo menos um de seu(s) filho(s). No caso de mães com ensino superior, completo ou incompleto, apenas 22,77% ( $IC_{95\%} = [14, 59\%; 30, 95\%]$ ) tiveram registros de óbitos para pelo menos um de seus filhos.

No quesito racial mães pardas são ampla maioria. Registrou-se que 93,30% ( $IC_{95\%} = [92, 37\%; 94, 22\%]$ ) das mulheres são pardas. Mães declaradas brancas foram apenas 5,38% ( $IC_{95\%} = [4, 54\%; 6, 21\%]$ ), pretas 1,28% ( $IC_{95\%} = [1, 07\%; 1, 49\%]$ ) e indígena apenas uma (Tabela 1). Pode-se concluir que 31,16% ( $IC_{95\%} = [29, 38\%; 32, 93\%]$ ) das mães pardas não obtiveram êxito em pelo menos uma gestação. Esse número é de 38,89% das mães declaradas pretas.

Quanto a idade verificou-se que, em média, as mães tem 27,63 anos ( $IC_{95\%} = [27, 43; 27, 82]$ ) com números variando dos 13 anos e 50 anos de idade. Os registros foram alocados em quatro

faixas etária conforme observado na Tabela 1. A classe de mulheres com idade entre 23 e 27 anos obteve maior frequência, foram 814 pacientes, ou seja 29% ( $IC_{95\%} = [27, 32\%; 30, 68\%]$ ) do total, seguida de perto pelo grupo de mulheres que possuem entre 32 e 50 anos de idade, que registrou 769 casos, 27,40% ( $IC_{95\%} = [25, 75\%; 29, 04\%]$ ) do total (Tabela 1). Registrou-se 103 casos de mães menores de idade, ou seja entre 13 e 17 anos, das quais 46 não tiveram êxito em pelo menos uma gestação.

Usando o método *stepwise*, observando os critérios AIC e o desvio residual, o melhor modelo encontrado foi ajustado para a função

$$\log\left(\frac{\theta_i}{1-\theta_i}\right) = -1,2695 - 0,0479I + 0,5914\nu + 0,3063\tau_2 + 0,3278\gamma_3 + 0,5906\gamma_4 + 0,7203\gamma_6 \quad (3)$$

O modelo (3) registrou  $AIC = 3116,1$  e desvio residual 3092,1. Esse modelo obteve o menor AIC e um desvio residual semelhante ao modelo saturado, embora ligeiramente maior. Na Tabela 2 observa-se as estimativas dos parâmetros e seus respectivos intervalos de confiança. Detecta-se que, com relação aos níveis de situação conjugal, mulheres casadas se diferenciam estatisticamente dos demais níveis quanto a chance de óbito do filho. Em relação aos graus de instrução, mulheres com ensino fundamental II, ensino médio e ensino superior completo se diferenciam das mulheres analfabetas, com ensino fundamental I e/ou com ensino superior completo.

Tabela 2: Estimativas de máxima verossimilhança dos parâmetros do modelo reduzido com tendência linear na variável idade e respectivos intervalos de confiança.

Parâmetro	Estimativa	E. P.	valor z	$IC_{2,5\%}$	$IC_{97,5\%}$	$Pr(> z )$
Intercepto	-1,2695	0,241	-5,27	-1,741	-0,797	0,001***
Idade (I)	-0,0479	0,008	-5,65	-0,064	-0,031	0,001***
Número de Gestações ( $\nu$ )	0,5914	0,036	16,60	0,522	0,661	0,001***
<b>Situação Conjugal</b>						
Casada ( $\tau_2$ )	0,3063	0,106	2,88	0,098	0,515	0,004**
<b>Grau de Instrução</b>						
E. Fundamental II ( $\gamma_3$ )	0,3278	0,119	2,75	0,094	0,561	0,006**
E. Médio ( $\gamma_4$ )	0,5906	0,130	4,53	0,335	0,846	0,001***
E. S. Completo ( $\gamma_6$ )	0,7203	0,311	2,32	0,111	1,329	0,020*

\*\*\* Significante a 0,001    \*\* Significante a 0,01    \* Significante a 0,05

A Figura 1 mostra o envelope simulado dos resíduos para o modelo reduzido com tendência linear na variável idade. Observa-se que o modelo é significativo, a 0,05 de significância, pois há apenas 3,95% dos pontos simulados fora do envelope. Em outras palavras, o modelo se ajusta aos dados e todas as suas variáveis são significativas. Neste caso, pode-se conservar a hipótese de que o modelo se ajusta aos dados.

Após atualização dos parâmetros utilizando os métodos bayesianos o modelo é dado pela equação (4) a seguir.

$$\log\left(\frac{\theta_i}{1-\theta_i}\right) = -1,26011 - 0,04864I + 0,59535\nu + 0,30285\tau_2 + 0,32936\gamma_3 + 0,59074\gamma_4 + 0,72752\gamma_6 \quad (4)$$

O modelo ajustado por verossimilhança, (3), é bastante semelhante ao modelo Bayesiano, (4). Observa-se essa semelhança pela proximidade dos valores dos parâmetros. Os valores preditos pelos dois modelos também se assemelham, conforme mostra a Tabela 3 e a Tabela 4. O modelo (3) mostra 1881 casos de crianças nascidas vivas, confirmado pelos dados, e 127 casos de óbitos




Figura 1: Envelope simulado para os resíduos do modelo reduzido com tendência linear na variável idade.

Tabela 3: Matriz de confusão do modelo (3).

		Valores Preditos	
		Nascido vivo	Óbito
Valores Reais	Nascido vivo	1811	127
	Óbito	649	220

dados que nasceram vivas. O mesmo modelo também nos diz que 649 casos de crianças nascidas vivas quando na verdade elas foram casos de óbito e 220 casos de óbitos confirmados pelos dados.

O modelo Bayesiano (4) mostra resultado bastante semelhante. Esse modelo mostra 1810 casos de crianças que nasceram vivas, casos estes confirmados pelos dados, enquanto que 128 casos foram registrados como óbito erroneamente. Portanto o modelo (3) obteve 1 acerto a mais que o modelo Bayesiano. O modelo (4) ainda detecta 649 casos de nascidos vivos quando, na verdade, os indivíduos foram a óbito e 220 casos de óbitos quando os indivíduos foram a óbito.

Tabela 4: Matriz de confusão do modelo (4).

		Valores Preditos	
		Nascido vivo	Óbito
Valores Reais	Nascido vivo	1810	128
	Óbito	649	220

Na Tabela 5 tem-se a acurácia, a taxa positiva verdadeira (TP), a taxa de falsos positivos (FP), a taxa negativa verdadeira (TN), a taxa de falsos negativos (FN), e a precisão para os dois modelos ajustados. Os valores são praticamente iguais, alguns diferem muito pouco. O modelo (4) tem uma acurácia um pouco maior enquanto que o modelo (3) tem maior precisão.

Tabela 5: Indicadores dos modelos ajustados.

	Acurácia	TP	FP	TN	FN	Precisão
Modelo (3)	0,7232	0,2532	0,0655	0,9344	0,7468	0,6340
Modelo (4)	0,7235	0,2532	0,0660	0,9339	0,7468	0,6322

## Conclusão

Neste trabalho pôde-se constatar que a idade da mãe é um fator que interfere diretamente na chance de uma criança vir a óbito no período perinatal assim como o número de gestações. As outras variáveis que interferem são o fato da mãe ser casada e ter ensino fundamental II, ter ensino médio ou curso superior completo.

Os modelos, tanto estimado pelo método da máxima verossimilhança quanto o modelo atualizado pelo Teorema de Bayes predizem resultados muito próximos. Os parâmetros do modelo Bayesiano não apresentou grande diferença para os valores dos parâmetros do modelo clássico.

## Referências

- BOLFARINE, H.; SANDOVAL, M. C. *Introdução à Inferência Estatística*. Rio de Janeiro: [s.n.], 2001.
- CORDEIRO, G. M.; DEMETRIO, C. G. *Modelos lineares generalizados e extensões*. Sao Paulo, 2008.
- CORDEIRO, G. M.; PAULA, G. A. *Modelos de regressão para análise de dados univariados*. São Paulo: IMPA, 1989.
- DEMETRIO, C. B. *Modelos lineares generalizados e extensões*. Statistical modelling, Springer Verlag, v. 57, p. 95, 1989.
- FONSECA, J.S.; MARTINS, G.A. *Curso de estatística*. 6.ed. São Paulo : Atlas, 1996. 320p.
- KINAS, P. G.; ANDRADE, H. A. *Introdução à análise bayesiana (com R)*. São Paulo: Consultor Editorial, 2010. ISBN 978-85-61797-10-2.
- MARDIA, K. V.; MARSHALL, R. J. Maximum likelihood estimation of models for residual covariance in spatial regression. *Biometrika*, Oxford University Press, v. 71, n. 1, p. 135-146, 1984.
- MORAL, R. A.; HINDE, J.; DEMETRIO, C. G. Half-normal plots and overdispersed models in R: The hnp package. *Journal of Statistical Software*, v. 81, n. 10, p. 1-23, 2017.
- NELDER, J. A.; BAKER, R. J. *Generalized linear models*. New York: Wiley Online Library, 1972.
- PAULA, G. A. *Modelos de regressão: com apoio computacional*. São Paulo: IME-USP, São Paulo, 2004.
- PAULINO, C. D. M.; TURKMAN, M. A. A.; MURTEIRA, B. *Estatística bayesiana*. Lisboa: Fundação Calouste Gulbenkian, 2003. ISBN 972-31-1043-1.
- PICHE, R.; PENTTINEN, A. *Bayesian methods*. Tampere University of Technology, Tampere. 2010.
- VICTORA, C. G. et al. *Saúde de mães e crianças no Brasil: progressos e desafios*. Lancet, 2011.