



Identificação das anomalias congênicas baseado em um modelo de decisão a partir de redes neurais artificiais

Identification of congenital anomalies based on a decision model from artificial neural networks

Identificación de las anomalías congénitas basado en un modelo de decisión a partir de redes neuronales artificiales

Luciana Moura Mendes de Lima¹, Rodrigo Pinheiro de Toledo Vianna², Ronei Marcos de Moraes²

RESUMO

Descritores:

Malformações
Congênicas; Nascido
Vivo; Técnicas de Apoio
à Decisão

Objetivo: Identificar os tipos de anomalias congênicas do sistema nervoso a partir de um modelo de tomada de decisão. **Método:** Estudo de natureza tecnológica e retrospectiva utilizando dados secundários provenientes do Sistema de Informação de Nascidos Vivos, com posterior identificação das anomalias realizada por meio de Redes Neurais Artificiais, no período de 2009 a 2014, no estado da Paraíba. **Resultados:** Foram utilizadas Redes Neurais Artificiais do tipo *perceptron* de múltiplas camadas, *feedforward* com algoritmo de treinamento *backpropagation*. Sua configuração foi composta por uma camada de entrada com 14 neurônios, 2 camadas ocultas uma com 22 neurônios e a outra com 10 e uma camada de saída com 8 neurônios e identificou corretamente 89,6% dos tipos de anomalias do sistema nervoso. **Conclusão:** O modelo permitiu identificar os tipos de anomalias congênicas do sistema nervoso, podendo ser útil no apoio aos gestores públicos e profissionais de saúde na tomada de decisão.

ABSTRACT

Keywords: Congenital
Abnormalities; Live
Birth; Decision Support
Techniques

Objective: To identify the types of congenital anomalies of the nervous system from a decision making model. **Methods:** Technological and retrospective study based on data from the Brazilian Live Birth Information System, with subsequent identification of the anomalies using Artificial Neural Networks, in the period from 2009 to 2014, in the state of Paraíba, Brazil. **Results:** It was used the multilayer perceptron type Artificial Neural Networks, feedforward with backpropagation training algorithm. Its configuration consisted of an input layer with 14 neurons, two hidden layers with 22 neurons and with 10, respectively and an output layer with 8 neurons. It identified 89,6% of the types of anomalies of the nervous system in correctly way. **Conclusion:** The model allowed identifying the types of congenital anomalies of the nervous system, being able to be useful in decision making support for public managers and professionals of health sciences.

RESUMEN

Descriptores:
Anomalías Congénitas;
Nacimiento Vivo;
Técnicas de Apoyo para
la Decisión

Objetivo: Identificar los tipos de anomalías congénitas del sistema nervioso a partir de un modelo de toma de decisión. **Método:** Estudio de naturaleza tecnológica y retrospectiva utilizando datos secundarios provenientes del Sistema de Información de Nacidos vivos, con posterior identificación de las anomalías realizada por medio de Redes Neuronales Artificiales, en el período de 2009 a 2014, en el estado de Paraíba. **Resultados:** Se utilizaron redes neuronales artificiales del tipo *perceptron* de múltiples capas, *feedforward* con algoritmo de entrenamiento *backpropagation*. Su configuración fue compuesta por una capa de entrada con 14 neuronas, 2 capas ocultas una con 22 neuronas y la otra con 10 y una capa de salida con 8 neuronas e identificó correctamente el 89,6% de los tipos de anomalías del sistema nervioso. **Conclusión:** El modelo permitió identificar los tipos de anomalías congénitas del sistema nervioso, demostrando ser útil en el apoyo a los gestores públicos y profesionales de salud en la toma de decisión.

¹ Fisioterapeuta e Doutoranda no Programa de Pós-Graduação em Modelos de Decisão e Saúde, Universidade Federal da Paraíba, João Pessoa (PB), Brasil.

² Professor. Programa de Pós-Graduação em Modelos de Decisão e Saúde, Universidade Federal da Paraíba, João Pessoa (PB), Brasil.

INTRODUÇÃO

As anomalias congênitas, também conhecidas como malformações congênitas, são defeitos estruturais ou funcionais que estão presentes ao nascimento, podem ter origem desconhecida, genética ou ambiental, afetando a saúde, desenvolvimento e/ou sobrevivência dos recém-nascidos⁽¹⁻²⁾. As causas das anomalias congênitas são amplas e complexas, 55% dessas apresentam causas desconhecidas, 30% causas genéticas e 15% ambientais⁽²⁾.

A incidência das anomalias é heterogênea e pode sofrer influência dos aspectos ambientais e socioculturais⁽³⁾. Estudos internacionais apresentam uma incidência que varia entre 2% e 2,5%^(1,4) e em países da América do Sul aproximadamente 1,0%⁽⁵⁾. No Brasil em torno de 1,2% e 2,5% dos nascidos vivos apresentam algum tipo de anomalia congênita⁽⁶⁻⁸⁾. Destaca-se dentre as causas mais importantes de mortalidade na infância⁽⁹⁾ e corresponde a segunda principal causa de óbito infantil no Brasil⁽¹⁰⁾. Entretanto, as mortes globais por anomalias no período de 1990 e 2013 apresentou uma redução mediana de 13,5%⁽¹⁰⁾.

De acordo com a Classificação Internacional de Doenças (CID-10) as anomalias podem ser identificadas em malformações congênitas do sistema nervoso; do olho, do ouvido, da face e do pescoço; do aparelho circulatório; do aparelho respiratório; fendas labiais e palatinas; outras malformações do aparelho digestivo; malformações congênitas dos órgãos genitais; do aparelho urinário; malformações e deformidades do aparelho osteomuscular; outras malformações congênitas e anomalias cromossômicas não classificadas em outra parte⁽¹¹⁾. No Brasil os dados referentes aos nascidos vivos são coletados a partir da Declaração de Nascido Vivo e registrados no Sistema de Informações sobre Nascidos Vivos (SINASC) com o intuito de fornecer informações acerca dos nascidos vivos, da mãe, da gravidez, do parto e outros⁽¹²⁾.

Dentre as possíveis anomalias descritas na CID-10, no Brasil, as anomalias do sistema nervoso são as mais frequentes^(7,13), enquanto na região Nordeste ocupa a segunda posição⁽¹⁴⁻¹⁵⁾. É relevante identificar os tipos de anomalias congênitas do sistema nervoso em relação às demais em virtude da sua alta frequência e gravidade dos casos, dessa maneira auxiliando os gestores públicos no processo de tomada de decisão. Assim, o presente estudo tem como objetivo identificar os tipos de anomalias congênitas do sistema nervoso a partir de um modelo de tomada de decisão.

MÉTODOS

Estudo de natureza tecnológica e retrospectiva utilizando dados secundários provenientes do SINASC, com posterior identificação das anomalias realizada por meio de Redes Neurais Artificiais (RNA), no período de 2009 a 2014, no estado da Paraíba. Os dados secundários foram obtidos por meio do Departamento de Informática do Sistema Único de Saúde de domínio público. Foram selecionadas 14 variáveis, referentes às características da mãe (idade, estado civil, escolaridade, quantidade de filhos vivos e mortos), da gravidez e parto (número de consultas no pré-

natal, semanas gestacional, tipo de parto) e do nascido vivo (Índice de Apgar no 1º e 5º minuto, sexo, peso, raça, município de nascimento) por serem mais relevantes com respeito ao objeto de estudo.

As anomalias congênitas do sistema nervoso de acordo com o CID-10 são classificadas em oito grupos sendo elas: anencefalia e malformações similares, encefalocele, microcefalia, hidrocefalia, outras malformações congênitas do cérebro, espinha bífida, outras malformações congênitas do Sistema Nervoso Central (SNC) e outras malformações congênitas da medula espinhal⁽¹¹⁾.

Para o presente estudo foi utilizado as RNA que são modelos computacionais inspirados no cérebro humano com o intuito de resolver problemas complexos, lidar com dados imprecisos ou situações não lineares. As principais características do método são: a habilidade de generalização, aprendizagem por ambiente, a partir de exemplos, e adaptabilidade⁽¹⁶⁾. Dadas essas características e propriedades as RNA foram escolhidas como base no modelo de apoio à decisão.

O modelo de RNA *perceptron* de múltiplas camadas apresenta uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A camada de entrada recebe as variáveis e transmite para a camada oculta, por sua vez, processa as informações e a camada de saída apresenta o resultado final⁽¹⁶⁾. Logo, os números de neurônios nas camadas ocultas variam dependendo da complexidade do problema e o número adequado foi selecionado com base no menor valor do erro⁽¹⁶⁾. Além disso, os sinais propagam-se em apenas uma direção a partir da camada de entrada, denominando de *feedforward*⁽¹⁶⁾.

Nas RNA um sinal x_j na camada de entrada conectado ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Em seguida, ocorre a soma dos sinais de entrada ponderada pelos pesos constituindo o combinador linear, representado por u_k . No entanto, pode incluir um *bias* aplicado externamente, corresponde ao b_k , que tem o intuito de aumentar ou diminuir a entrada da função de ativação. Já a função de ativação define a saída do neurônio e transfere o resultado para os neurônios na camada de saída⁽¹⁶⁾. De maneira geral, um neurônio artificial pode ser representado segundo as equações (1) e (2)⁽¹⁶⁾:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde: u_k é o combinador linear, w_{kj} é o peso sináptico do neurônio k , x_j é o sinal de entrada do neurônio, y_k é o sinal de saída do neurônio, $\varphi(\cdot)$ é a função de ativação e b_k é o *bias*.

Além disso, as redes são “treinadas” ajustando os pesos sinápticos de modo a minimizar o erro para um limite aceitável, este processo é denominado de algoritmo de treinamento. O algoritmo de treinamento mais utilizado é *backpropagation*, que consiste em duas etapas: a propagação, que é um passo para frente; e a retropropagação, que consiste em um passo para trás, no qual ocorre um ajuste nos pesos

com o intuito de minimizar o erro⁽¹⁶⁾. Este erro pode ser calculado da seguinte forma⁽¹⁶⁾:

$$e_j(n) = d_j(n) - y_j(n) \quad (3)$$

onde: $e_j(n)$ é sinal de erro de um neurônio de saída j , n é o instante de tempo discreto, $d_j(n)$ é a resposta desejada para o neurônio j e $y_j(n)$ é o sinal de saída do neurônio j .

Outros parâmetros como *momentum*, taxa de aprendizagem e épocas são importantes na implementação do modelo. O *momentum* tem o objetivo de aumentar a velocidade do treinamento e deve apresentar valor inferior a um, enquanto a taxa de aprendizagem corresponde ao tamanho do passo em direção da alteração dos pesos sinápticos. Quanto menor for esta taxa mais suave será sua trajetória entre os pesos, o que torna a rede mais estável. As épocas correspondem ao número de vezes que os padrões de treinamento serão apresentados às RNA e são repetidas até alcançar algum critério de parada⁽¹⁶⁾.

Para verificar a qualidade da RNA foi elencada a matriz de confusão, coeficiente Kappa, medidas de sensibilidade e especificidade e curva *Receiver Operating Characteristic* (ROC). Esta primeira é uma matriz quadrada de dimensão igual ao número de identificações que tem como objetivo mensurar a precisão do modelo. Na diagonal principal apresentam as decisões corretas e fora dela, as decisões incorretas. Uma forma simples de se medir o percentual de decisões corretas é a partir da soma dos valores na diagonal principal da matriz, dividida pela soma de todos os elementos desta⁽¹⁷⁾. Entretanto, o coeficiente Kappa tem como intuito verificar o grau de concordância entre os acertos e também os erros alcançados por meio da matriz de confusão⁽¹⁸⁾. Quanto mais próximo de um o coeficiente Kappa, maior o grau de concordância do modelo de decisão⁽¹⁹⁾. O cálculo procede da seguinte maneira:

$$K = \frac{P_0 - P_C}{1 - P_0} \quad (4)$$

onde:

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N} \quad e \quad P_C = \frac{\sum_{i=1}^M n_{i+} + n_{+i}}{N^2} \quad (5)$$

onde: n_{ii} elementos da diagonal principal da matriz de confusão, n_{i+} total da linha i da matriz, n_{+i} total da coluna i da matriz, M é o número total de classes e N é o número total de decisões presentes na matriz.

As medidas de sensibilidade e especificidade tem o objetivo de diagnosticar corretamente os indivíduos doentes e não-doentes, respectivamente⁽²⁰⁾. Foi utilizado no presente estudo com a finalidade de averiguar a identificação correta referente a cada tipo de anomalia congênita do sistema nervoso. A curva ROC foi usada para examinar o poder discriminativo do modelo⁽²⁰⁾.

Os dados citados no início desta seção foram tabulados em uma planilha eletrônica e analisados no *software Waikato Environment for Knowledge Analysis* (WEKA), versão 3.8, desenvolvido na Universidade de Waikato, Nova Zelândia,

distribuído sob os *termos General Public License*. Como os dados utilizados foram de domínio público não houve a necessidade de apreciação do Comitê de Ética em Pesquisa.

RESULTADOS E DISCUSSÃO

Foram notificados 288 casos de nascidos vivos com anomalias congênitas do sistema nervoso, 2009 a 2014, no estado da Paraíba. Desses, 51,0% eram do sexo feminino, em geral o peso exibiu uma média de 2781,2 gramas. O Índice de Apgar no 1º minuto apresentou uma média aproximadamente 6,0 e no 5º minuto 7,1. Foi verificado que 26,4% dos nascidos vivos apresentaram anencefalia e malformações similares, 33,3% hidrocefalia, 17,7% espinha bífida, 8% outras malformações congênitas do sistema nervoso, 7,3% encefalocele e 7,3% microcefalia. No presente estudo foram agrupadas outras malformações congênita do SNC, outras malformações congênitas do cérebro e outras malformações congênitas da medula espinal em outras malformações congênitas do sistema nervoso.

Foi utilizado a RNA *perceptron* de múltiplas camadas do tipo *feedforward*, com o algoritmo de treinamento *backpropagation*. Adicionalmente foi usado à taxa de aprendizado (0,2), *momentum* (0,3) e 500 ciclos de operação. A configuração que apresentou os melhores resultados foi constituída por 14 neurônios na camada de entrada, já citadas na seção anterior, 2 camadas ocultas uma com 22 neurônios e a outra com 10 neurônios e uma camada de saída com 8 neurônios. Foi aplicado o conjunto de dados para teste e treinamento.

Com o conjunto de dados para treinamento o modelo de decisão baseado na RNA, identificou corretamente 94,1% dos tipos das anomalias, com um coeficiente Kappa de 92,3% de concordância representando um modelo de decisão quase perfeito, conforme Landis e Koch (1977)⁽¹⁹⁾. O conjunto de teste foi constituído por uma seleção aleatória de 30% do conjunto de dados de treinamento e a mesma RNA identificou corretamente 89,6% dos tipos das anomalias. De acordo com a matriz de confusão apresentada na Figura 1, a RNA obteve mais acertos em relação à espinha bífida. Por meio do coeficiente Kappa foi constatado 86,3% de concordância (p -valor $< 0,001$) representando um modelo de decisão quase perfeito, conforme Landis e Koch (1977)⁽¹⁹⁾.

A Tabela 1 foi composta pelos testes de sensibilidade, especificidade e curva ROC das anomalias congênitas do sistema nervoso no estado da Paraíba como pode ser observado. Foi constatado que a microcefalia tem apresentado a menor sensibilidade em virtude de um número maior de falsos positivos. Foi verificado que a curva ROC apresenta uma excelente precisão com valores superiores a 95%, exceto em outras malformações congênitas do sistema nervoso, que apresenta muito boa precisão.

O modelo de decisão baseado em RNA permitiu identificar as anomalias congênitas conforme agrupamento apresentando poucos erros (10), conforme mostrado na Figura 1. A microcefalia apresentou um número maior de erros, identificando dois casos como hidrocefalia e

a	b	c	d	e	f	<-- Identificado como
6	0	0	0	2	0	a=Outras malformações congênicas do sistema nervoso
0	4	1	0	0	0	b=Encefalocele
0	0	7	2	2	0	c=Microcefalia
0	0	0	29	0	2	d=Hidrocefalia
0	0	0	0	27	1	e=Anencefalia e malformações similares
0	0	0	0	0	13	f= Espinha bífida

Figura 1 - Matriz de confusão dos nascidos vivos com anomalia congênita do sistema nervoso, no período de 2009 a 2014, no estado da Paraíba.

Tabela 1 - Teste de sensibilidade, especificidade e curva ROC.

Tipos de anomalias	Sensibilidade	Especificidade	Curva ROC
Outras malformações congênicas do sistema nervoso	75,0%	100%	83,7%
Encefalocele	80,0%	100%	99,9%
Microcefalia	63,6%	98,8%	99,0%
Hidrocefalia	93,5%	96,9%	99,7%
Anencefalia e malformações similares	96,4%	94,1%	98,4%
Espinha bífida	100%	96,3%	99,6%

dois casos como anencefalia e malformações similares. Esses achados poderão auxiliar os gestores públicos no planejamento e desenvolvimento de ações voltadas ao pré-natal, a necessidade de serviços especializados, como também ampliar o olhar para esta demanda. O coeficiente Kappa demonstrou um grau de concordância do modelo de tomada de decisão quase perfeito corroborando com outra investigação que analisou a consistência diagnóstica entre um conjunto de dados da Espanha e a documentação clínica na identificação de nascidos vivos com anomalias congênicas e verificou valor do Kappa semelhante ao presente estudo⁽²¹⁾.

No que diz respeito ao modelo de decisão, RNA, diversas vantagens podem ser citadas: a utilização de dados qualitativos e/ou quantitativos, fornecimento de solução eficaz para questões com diversas variáveis⁽¹⁶⁾ por isso tem sido considerado um modelo de decisão eficiente na área da saúde, mas envolve que um esforço computacional. Uma pesquisa com o objetivo de estimar o peso fetal com base nas RNA examinou 2127 fetos três dias antes do parto em que 70% foram atribuídos aleatoriamente ao grupo de treinamento do modelo de RNA e os outros 30% foram utilizados para validar. Foi verificada a importância de elencar um parâmetro de agrupamento específico para o método melhorar a precisão do peso fetal estimado⁽²²⁾. A RNA também foi utilizada para prever o tipo de atividade física e o gasto energético em crianças e adolescentes na faixa etária entre 5 e 15 anos, em uma amostra de 100 participantes, constatou uma acurácia entre 81,3% e 88,4% a depender da configuração da rede⁽²³⁾.

Em relação a RNA e as anomalias do sistema nervoso, uma pesquisa investigou a previsão da infecção por *shunt*, *shunt* é um material que auxilia na drenagem do excesso de líquido na cabeça de uma criança com hidrocefalia, em 148 crianças com hidrocefalia aplicando dois métodos de tomada de decisão, a RNA *perceptron* de múltiplas camadas com o algoritmo de treinamento *backpropagation* e a regressão logística, foi verificado 86,4% e 55,7% de

acurácia, respectivamente⁽²⁴⁾.

Outro estudo empregou a RNA *perceptron* de múltiplas camadas com o *backpropagation* para as neuropróteses, técnicas que permitem que indivíduos paralisados controlem seus membros voluntariamente, em indivíduos com espinha bífida com a finalidade de verificar se poderia usar a ativação neuromuscular registrada de indivíduos com medula espinhal prejudicada para prever seus parâmetros finais de marcha (como comprimento da passada e largura da passada) e averiguou que este modelo tem uma acurácia acima de 80%⁽²⁵⁾.

Foi evidenciado que os estudos não relacionaram um modelo de tomada de decisão à identificação dos tipos das anomalias congênicas, assim demonstrando a importância desta investigação. Pode citar como limitação do estudo o processo exaustivo para encontrar a configuração adequada a RNA.

CONCLUSÃO

O modelo de decisão, RNA, permitiu identificar os tipos de anomalias congênicas do sistema nervoso e com um grau de concordância quase perfeito. Esses achados podem subsidiar os gestores públicos no planejamento e tomada de decisão sobre o desenvolvimento de ações voltadas ao pré-natal e a outros serviços especializados. Este método pode ser utilizado para identificação de outros grupos de doenças e também em aplicações em áreas do conhecimento humano em tarefas similares. Como futuros trabalhos podem ser sugeridos investigações que ampliem os casos para outras anomalias, como exemplo do aparelho circulatório.

AGRADECIMENTOS

Apoio financeiro a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)/Fundação de Apoio à Pesquisa do Estado da Paraíba (FAPESQ-PB).

REFERÊNCIAS

1. Kliegman R, Stanton BF, St Geme J, Schor NF. Nelson Tratado de Pediatria. In: Slavotinek A. Disfomorfologia. 20a ed. Rio de Janeiro: Elsevier; 2017.
2. Sadler TW. Langman, Embriologia Médica. In: Defeitos congênitos e diagnóstico pré-natal. 13a ed. Rio de Janeiro: Guanabara Koogan; 2016.
3. Gili JA, Poletta FA, Pawluk M, Gimenez LG, Campaña H, Castilla E, et al. High birth prevalence rates for congenital anomalies in South American regions. *Epidemiology*. 2015;26(5):e53-5.
4. Martin RJ, Fanaroff AA, Walsh MC. Fanaroff & Martin: Medicina neonatal e perinatal-doenças do feto e do neonato. In: Parikh AS, Mitchell AL. Anomalias congênitas. 10a ed. Brasil: Elsevier; 2016.
5. Gili JA, Poletta FA, Giménez LG, Pawluk MS, Campaña H, Castilla EE, et al. Descriptive analysis of high birth prevalence rate geographical clusters of congenital anomalies in South America. *Birth Defects Res A Clin Mol Teratol*. 2016 Apr;106(4):257-66.
6. Cosme HW, Lima LS, Barbosa LG. Prevalência de anomalias congênitas e fatores associados em recém-nascidos do município de São Paulo no período de 2010 a 2014. *Rev Paul Pediatr*. 2017 Jan-Mar;35(1):33-8.
7. Almeida LF, Araujo Júnior E, Crott GC, Okido MM, Berezowski AT, Duarte G, et al. Epidemiological risk factors and perinatal outcomes of congenital anomalies. *Rev Bras Ginecol Obstet*. 2016 Jul;38(7):348-55.
8. Mendes CQS, Avena MJ, Mandetta MA, Balieiro MM. Prevalência de nascidos vivos com anomalias congênitas no município de São Paulo. *Rev Soc Bras Enferm Ped*. 2015;15(1):7-12.
9. Naghavi M, Wang H, Lozano R, Davis A, Liang X, Zhou M, et al. Global, regional, and national age-sex specific all-cause and cause-specific mortality for 240 causes of death, 1990-2013: a systematic analysis for the Global Burden of Disease Study 2013. *Lancet*. 2015; 385(9963):117-71.
10. França EB, Lansky S, Rego MA, Malta DC, França JS, Teixeira R, et al. Principais causas da mortalidade na infância no Brasil, em 1990 e 2015: estimativas do estudo de Carga Global de Doença. *Rev Bras Epidemiol*. 2017;20(1):46-60.
11. Organização Mundial de Saúde. Classificação Estatística Internacional de Doenças: CID-10. São Paulo: Ed USP; 2008.
12. Brasil. Ministério da Saúde. Secretaria de Vigilância em Saúde. Departamento de Análise de Situação de Saúde. Manual de instruções para o preenchimento da Declaração de Nascido Vivo. Brasília: Ministério da Saúde; 2011.
13. Westphal F, Fustinoni SM, Pinto VL, Melo PS, Abrahão AR. Associação da idade gestacional com a opção pela interrupção da gravidez de fetos com anomalias incompatíveis com a sobrevivência neonatal. *Einstein*. 2016 Jul-Set;14(3):311-6.
14. Fontoura FC, Cardoso MVLML. Associação das malformações congênitas com variáveis neonatais e maternas em unidades neonatais numa cidade do nordeste brasileiro. *Texto Contexto Enferm*. 2014 Out-Dez;23(4):907-14.
15. Rodrigues LS, Lima RHS, Costa LC, Batista RFL. Características das crianças nascidas com malformações congênitas no município de São Luís, Maranhão, 2002-2011. *Epidemiol Serv Saúde*. 2014;23(2):295-304.
16. Haykin S. Redes neurais: princípios e prática. 2a ed. Porto Alegre: Bookman; 2001.
17. Foody GM. Status of land cover classification accuracy assessment. *Remote Sens. Environ*. 2002 Apr;80(1):185-201.
18. Cohen J. A coefficient of agreement for nominal scales. *Educ Psychol Meas*. 1960 Apr;20(1):37-46.
19. Landis JR, Koch GG. The measurement of observer agreement for categorical data. *Biometrics*. 1977; 33(1):159-74.
20. Borges LS. Medidas de acurácia diagnóstica na pesquisa cardiovascular. *Int J Cardiovasc Sci*. 2016;29(3):218-22.
21. Cavero-Carbonell C, Gimeno-Martos S, Zurriaga Ó, Rabanaque-Hernández MJ, Martos-Jiménez C. La validez del Conjunto Mínimo Básico de Datos como fuente de identificación de las anomalías congénitas en la Comunitat Valenciana. *Gac Sanit*. 2017;31(3):220-6.
22. Cheng YC, Yan GL, Chiu YH, Chang FM, Chang CH, Chung KC. Efficient fetal size classification combined with artificial neural network for estimation of fetal weight. *Taiwan J Obstet Gynecol*. 2012 Dez; 51(4):545-53.
23. Trost SG, Wong WK, Pfeiffer KA, Zheng Y. Artificial neural networks to predict activity type and energy expenditure in youth. *Med Sci Sports Exerc*. 2012 Sep;44(9):1801-09.
24. Habibi Z, Ertiaei A, Nikdad MS, Mirmohseni AS, Afarideh M, Heidari V, et al. Predicting ventriculoperitoneal shunt infection in children with hydrocephalus using artificial neural network. *Childs Nerv Syst*. 2016 Nov;32(11):2143-51.
25. Chang CL, Jin Z, Chang HC, Cheng AC. From neuromuscular activation to end-point locomotion: an artificial neural network-based technique for neural prostheses. *J Biomech*. 2009 May;42(8):982-88.