

Classificação de Autocuidados Necessários para Crianças com Incapacidades Físicas e Motoras Utilizando Redes Neurais Artificiais

Emanoel Lucas Rodrigues Costa¹, Náthalee Cavalcanti de Almeida Lima¹

¹Universidade Federal Rural do Semi-Árido – UFERSA – Pau dos Ferros – RN – Brasil

lucasrodrigues52@gmail.com, nathalee.almeida@ufersa.edu.br

Abstract. *The ICF-CY, is a document developed by the World Health Organization (WHO) that aims to register characteristics related to the development of children/young and the influence of the environment around them. The SCADI dataset [Zarchi, Fatermi & Dehghanizadeh], has data based on the ICF-CY which with the application of the neural network MultiLayer Perceptron (MLP), that are computational models with capacity to acquire knowledge, were used in this paper to classify the self-care necessity for each child according to their limitations. The MLP presented satisfactory results in two different analyzed cases.*

Resumo. *A ICF-CY, é um documento desenvolvido pela Organização Mundial de Saúde (OMS) que tem por objetivo registrar características relacionadas ao desenvolvimento de crianças/jovens e a influência do ambiente ao seu redor. O banco de dados SCADI [Zarchi, Fatermi & Dehghanizadeh], dispõe de dados baseados na ICF-CY os quais com a aplicação da rede neural Perceptron de Múltiplas Camadas (PMC), que são modelos computacionais com capacidade de aquisição de conhecimento, foram utilizados neste trabalho para classificação dos autocuidados necessários para cada criança de acordo com suas limitações. A PMC apresentou resultados satisfatórios em dois casos distintos analisados.*

1. Introdução

As altas incidências de doenças crônicas fizeram com que os estudos relacionados à mensuração de incapacidades e funcionalidades referentes a pessoas deficientes despertassem um crescente interesse [Castaneda, Bergmann & Bahia 2014]. Particularmente, a incapacidade se trata de uma categoria que muitas vezes pode apresentar ambiguidades, o que levou a Organização Mundial de Saúde (OMS), há cerca de 30 anos, a desenvolver modelos de classificação e entendimento de fenômenos relacionados à funcionalidade, incapacidade e deficiência.

O objetivo da OMS era criar um modelo universal para fornecer uma representação biopsicossocial da saúde global, com contribuições ambientais, sociais, demográficas e psicológicas, sendo elaborada uma classificação para descrever as consequências advindas da saúde ou doenças, que ficou conhecida como Classificação Internacional de Deficiências, Incapacidades e Desvantagens (CIDID) [Castaneda, Bergmann & Bahia 2014]. Porém, devido a críticas e questionamentos sobre a necessidade de adequação do modelo, surgiu em 2001 a Classificação Internacional de Funcionalidade, Incapacidade e Saúde, do inglês *International Classification of Functioning Disability and Health – ICF*.

A ICF fornece um quadro de classificação mundialmente aceito para concretizar e descrever o conceito de funcionalidade, incapacidade e saúde de pessoas com todos os tipos de doenças ou condições, sendo seu conteúdo estruturado de forma hierárquica com capítulos que constituem níveis de precisão contendo categorias em seus níveis. Por exemplo, existe o capítulo sobre Mobilidade que apresenta no segundo nível a categoria d440 “Uso da mão Fina” e no terceiro nível a categoria d4401 “Agarramento” [Herrmann *et al.* 2011]. Outro modelo de classificação é a *International Classification of Functioning, Disability and Health for Children and Youth (ICF-CY)* [World Health Organization 2007], que é derivada da ICF e destina-se a registrar as características do desenvolvimento de crianças e a influência do ambiente que a envolve, podendo ser utilizada por provedores, consumidores e todos aqueles preocupados com a saúde, educação e bem estar das crianças e jovens. Essa classificação se baseia na estrutura conceitual da ICF, utilizando uma linguagem comum para registrar problemas envolvendo funções e estruturas do corpo, limitações de atividades e restrições de participação manifestadas na infância e adolescência.

Um método bastante utilizado na classificação de dados são as Redes Neurais Artificiais, que tratam-se de modelos computacionais inspirados no sistema nervoso de seres vivos e possuem a capacidade de aquisição e manutenção de conhecimento com base em informações fornecidas, possuindo como características principais a adaptação por experiência, habilidade de generalização, organização de dados, entre outras [Silva, Spatti & Flauzino 2010].

Neste trabalho foram utilizados dados obtidos com base na ICF-CY para identificar problemas envolvendo funções e estruturas do corpo de 70 crianças com incapacidade física e motora. Os dados foram provenientes do banco de dados SCADI [Zarchi, Fatermi & Dehghanizadeh 2018], que possui um conjunto de dados para classificação de problemas de autocuidado. O objetivo é fazer uso de uma Rede Neural Artificial, mais especificamente a rede Perceptron de Múltiplas Camadas (PMC), para classificar em determinadas classes quais seriam os cuidados necessários para cada criança de acordo com suas limitações.

2. International Classification of Functioning, Disability and Health for Children and Youth (ICF-CY)

A ICF-CY pertence a “família” de classificação internacional desenvolvida pela OMS para aplicação a vários aspectos de saúde. A família da OMS de classificações internacionais fornece uma estrutura para codificar uma ampla gama de informações sobre saúde tais como: diagnósticos, funcionamento e incapacidade, e razões para o contato com serviços de saúde, utilizando uma linguagem padronizada permitindo a comunicação sobre saúde e cuidados de saúde em todo o mundo em várias disciplinas e ciências [World Health Organization 2007].

Essa classificação foi desenvolvida para auxiliar clínicos, educadores, pesquisadores, administradores, políticos e pais na documentação de características de crianças e jovens que são de fundamental importância na promoção do seu crescimento, saúde e desenvolvimento. A ICF-CY surgiu devido a uma necessidade de uma versão do ICF que pudesse ser utilizado mundialmente para crianças e jovens na área da saúde e educação social, já que as manifestações de incapacidade e condições de saúde em crianças e adolescentes divergem na intensidade e impacto da dos adultos [World Health Organization 2007]. Dessa forma, essas diferenças devem ser levadas em conta

para que o conteúdo da classificação seja sensível às mudanças associadas ao desenvolvimento, englobando as características de diferentes faixas etárias e ambientes, com cobertura desde o nascimento até os 18 anos de idade, comparando-se a outras convenções sobre a variedade de idade.

3. Banco de Dados SCADI

A classificação e o diagnóstico de problemas relacionados ao autocuidado (*Self-Care*) são considerados desafios importantes no que diz respeito a sistemas excepcionais de atenção a saúde infantil. O processo de classificação de problemas relacionados ao autocuidado trata-se de um processo demorado, que requer a disponibilidade de terapeutas ocupacionais especializados. Dessa forma, a utilização de um possível sistema especializado na classificação desses problemas poderia ser de grande ajuda, diminuindo os custos e tempo de forma eficiente [Zarchi, Fatermi & Dehghanizadeh 2018].

O banco de dados SCADI (*Self-Care Activities Dataset Based on ICF-CY*) trata-se de um conjunto de dados padrão, que é baseado na ICF-CY e de acordo com os autores é o primeiro banco de dados baseado nas atividades de autocuidado da ICF-CY onde 29 atividades de autocuidado são consideradas. O banco contém 205 atributos obtidos de 70 crianças que apresentam incapacidades físicas e motoras, sendo todos esses atributos baseados na seção de autocuidados da ICF-CY. Os atributos escolhidos são referentes ao primeiro nível de classificação da ICF-CY denominado “Atividades e Participações” e especificamente do Capítulo 5: “Autocuidados”. Os dados provenientes do banco levam em consideração os atributos das categorias do segundo nível que vai de d510 a d540. A Tabela 1 ilustra como estes atributos estão dispostos na ICF-CY e alguns atributos referentes a cada categoria no segundo nível.

Tabela 1: Atividades e Participações: Autocuidados.

Atributo 1º Nível	Capítulo 5: Autocuidados			
Atributo 2º Nível	d 510 (Lavar-se)	d 520 (Cuidar de Partes do Corpo)	d 530 (Necessidades Fisiológicas)	d 540 (Vestir-se)
Atributos 3º Nível	d 5100 (lavar partes do corpo) d 5101 (lavar o corpo inteiro) ⋮	d 5200 (cuidar da pele) d 5201 (cuidar dos dentes) ⋮	d 5300 (urinação regular) d 5301 (defecação regular) ⋮	d 5400 (vestir roupas) d 5301 (tirar roupas) ⋮

De acordo com os 205 atributos atribuídos a cada criança, ela é classificada em uma determinada classe de cuidados especiais que são necessários durante sua rotina diária. Todas as classes foram determinadas por terapeutas ocupacionais com bases nos atribuídos apresentados e sua análise profissional. A Tabela 2 descreve todas as classes dadas pelos terapeutas ocupacionais, que foram no total 7.

Tabela 2: classes de cuidados especiais.

Classe (Nº)	Descrição
1	Necessários cuidados com relação às partes do corpo
2	Problemas de Higiene
3	Problemas em vestir-se
4	Problemas em lavar-se, vestir-se e cuidar de partes do corpo
5	Problemas em lavar-se, vestir-se, cuidar de partes do corpo e higiene
6	Problemas em comer, beber, lavar-se, cuidar de partes do corpo, higiene, vestir-se, cuidar da própria saúde e cuidar de sua segurança
7	Nenhum problema

A ideia é utilizar esse conjunto de dados fornecido pelo banco SCADI para criar um sistema capaz de aprender e classificar corretamente as classes supracitadas, de acordo com os atributos conferidos a cada criança. Existem diversos métodos na área de inteligência artificial voltados para a análise dados e construção de modelos analíticos, capazes de aprender com dados e identificar padrões como, por exemplo, o KNN (K – *Nearest Neighbors*), *K-means*, *Random Forest*, Redes Neurais Artificiais entre outros.

Neste trabalho, optou-se por realizar o aprendizado de máquina utilizando o método de Redes Neurais artificiais, usando especificamente a rede PMC para classificação dos dados. O intuito é demonstrar que apesar do banco de dados fornecer pouca informação a respeito de determinadas classes, uma rede neural simples como a PMC é capaz de obter um bom desempenho em sua classificação, evidenciando assim a aplicabilidade de outras redes neurais e técnicas de classificação.

4. Redes Neurais Artificiais (RNA)

Redes Neurais Artificiais são modelos computacionais que foram inspirados no sistema nervoso dos seres vivos e possuem a capacidade de aquisição e manutenção de conhecimento (baseados em informações). De forma sucinta as Redes Neurais Artificiais podem ser definidas como um conjunto de unidades de processamento, caracterizados por neurônios artificiais, que são interligados por um grande número de interconexões, sendo essas representadas por vetores (ou matrizes) de pesos sinápticos [Silva, Spatti & Flauzino 2010]. A Figura 1 ilustra a composição de um único neurônio artificial, que é a base do entendimento e construção de outras redes neurais.




Figura 1: Neurônio artificial. Fonte: [Silva, Spatti & Flauzino 2010]

Os valores x_1, x_2, \dots, x_n representam os sinais de entrada, w_1, w_2, \dots, w_n os pesos sinápticos, Σ é o combinador linear, θ o limiar de ativação, u o potencial de ativação, g a função de ativação e y o sinal de saída. Uma das redes neurais mais utilizada é a rede *Perceptron* de Múltiplas Camadas, que são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) composta por neurônios, que deve ficar situada entre camada de entrada e a camada de saída. Dessa forma, as PMC devem possuir no mínimo duas camadas de neurônios, os quais são distribuídos entre as camadas intermediárias e a camada de saída.

O número de aplicações às quais a PMC pode ser aplicada é consideravelmente elevado o que faz com que essa arquitetura de rede seja uma das mais versáteis quanto à aplicabilidade. Algumas dessas áreas são: Aproximação de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais, entre outras [Silva, Spatti & Flauzino 2010]. A Figura 2 ilustra a arquitetura da rede PMC. Neste trabalho a rede PMC é utilizada com intuito de classificar em uma das classes definidas pelos especialistas, de acordo com os atributos identificados em cada criança.




Figura 2: Ilustração da rede *Perceptron Múltiplas Camadas*. Fonte: [Silva, Spatti & Flauzino 2010]


5. Metodologia

O banco de dados SCADI conta com um total de 206 atributos de 70 crianças das quais 7 classes foram identificadas, a Tabela 3 mostra o número de crianças de acordo com as classes. Algumas classes apresentam um número bem pequeno de crianças classificadas, como é o caso das classes 1, 3 e 5, o que acaba por prejudicar a distribuição dos dados entre as fases de treinamento e teste, já que não seria possível dividir as entradas em um percentual adequado nas fases da RNA. Devido a esse fato, optou-se por verificar os resultados obtidos em dois casos. No primeiro deles são analisadas a classificação de todas as classes, e no segundo caso somente as classes 2, 4, 6, e 7.

Tabela 3: Quantidade de crianças classificadas em cada classe.

Classe	Nº de crianças classificadas
1	2
2	7
3	1
4	12
5	3
6	29
7	16

No primeiro e segundo caso, os dados de treinamento e teste foram divididos de forma que na fase de teste fosse possível verificar os resultados referentes a todas as classes utilizadas. Assim, um total de 70 % das amostras foi utilizado na fase de treinamento e 30 % na fase de teste em ambos os casos. A Figura 3 ilustra a estrutura da rede PMC utilizada para classificação no primeiro e segundo caso.



(a)

(b)

Figura 3: Estrutura das redes PMC utilizadas: (a) Primeiro Caso, (b) Segundo Caso.

A topologia da rede com 20 neurônios na camada oculta foi escolhida após uma comparação com redes possuindo quantidades distintas de neurônios, escolhidos de forma arbitrária. O problema de classificação foi aplicado a redes com 10, 20, 30 e 40 neurônios na camada oculta, nas quais o melhor desempenho foi obtido com 20 neurônios. A rede foi aplicada utilizando o *software MATLAB* e tem como entrada 205 atributos relacionados ao ICF-CY sobre capacidade de autocuidado de crianças/jovens, 20 neurônios na camada intermediária, saídas destinadas a classificação em um determinado número classe e foi treinada até atingir um erro de 10^{-9} utilizando o método da entropia cruzada e o algoritmo de treinamento *Levenberg-Marquardt*.

A entropia cruzada vem sendo utilizada como uma medida de erro alternativa ao erro quadrático médio e comumente aplicada para quantificar a diferença entre duas distribuições de probabilidade. A entropia cruzada busca determinar o quão próxima uma determinada distribuição prevista está da distribuição verdadeira, para isso é utilizada a equação:

$$E = - \sum_{i=1}^n [(1-d_i) \log_2(1-a_i) + d_i \log_2(a_i)] \quad (1)$$

Onde a_i é o valor para uma saída i , d_i é o valor desejado para a saída i e n é a quantidade de saídas. Dessa forma, a entropia cruzada interpreta o sinal de treinamento e as saídas como probabilidades buscando minimizar a diferença entre elas. A principal vantagem de sua utilização em problemas de classificação é que ela descreve a perda entre duas distribuições de probabilidade, possibilitando assim com que o processo de treinamento de uma rede seja mais efetivo na busca de uma distribuição já conhecida.

6. Resultados

6.1 Primeiro caso (Todas as Classes Consideradas)

Ao se aplicar a rede apresentada na Figura 3 (a), obteve-se uma acurácia de 85% convergindo a um desempenho de 10^{-9} em um total de 72 épocas. A matriz de confusão para esse caso é apresentada na Figura 4 (a), ilustrando as escolhas das classes por parte da rede PMC já treinada, sendo as classes dispostas igualmente às apresentadas na Tabela 2.

O desempenho da rede na fase de treinamento é ilustrado na Figura 4 (b), a qual apresenta a diminuição do erro calculado pela medida da entropia cruzada de acordo com o número de épocas de treinamento até atingir o valor especificado. Como pode ser visto na Figura 4, a matriz de confusão obtida mostra que os principais erros na classificação estão justamente nas classes que apresentam a menor quantidade de entradas do banco de dados, as classes 1, 3 e 5. Porém, a acurácia obtida foi consideravelmente boa, devido à classificação correta das demais classes.

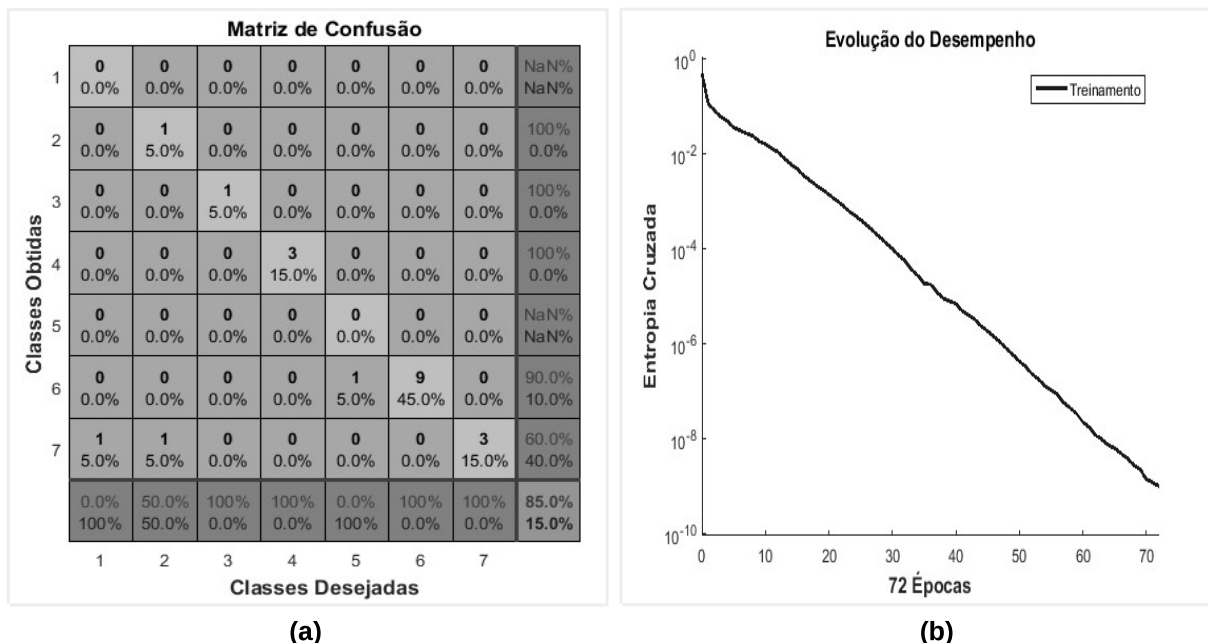


Figura 4: (a) Matriz de confusão no 1º caso, (b) Desempenho da rede PMC no 1º caso.

6.2 Segundo caso (classes 2, 4, 6 e 7)

A rede PMC apresentada na Figura 3 (b) foi aplicada, porém desta vez considerando apenas quatro classes. Foi obtida uma acurácia de 94,7 % convergindo a um desempenho de 10^{-9} em total de 53 épocas. A matriz de confusão para esse caso é apresentada na Figura 5 (a), ilustrando as escolhas das classes por parte da rede PMC já treinada. As classes 1, 2, 3 e 4 representam, respectivamente, as classes 2, 4, 6 e 7 referentes à Tabela 2. O desempenho da rede na fase de treinamento é ilustrado na Figura 5 (b).

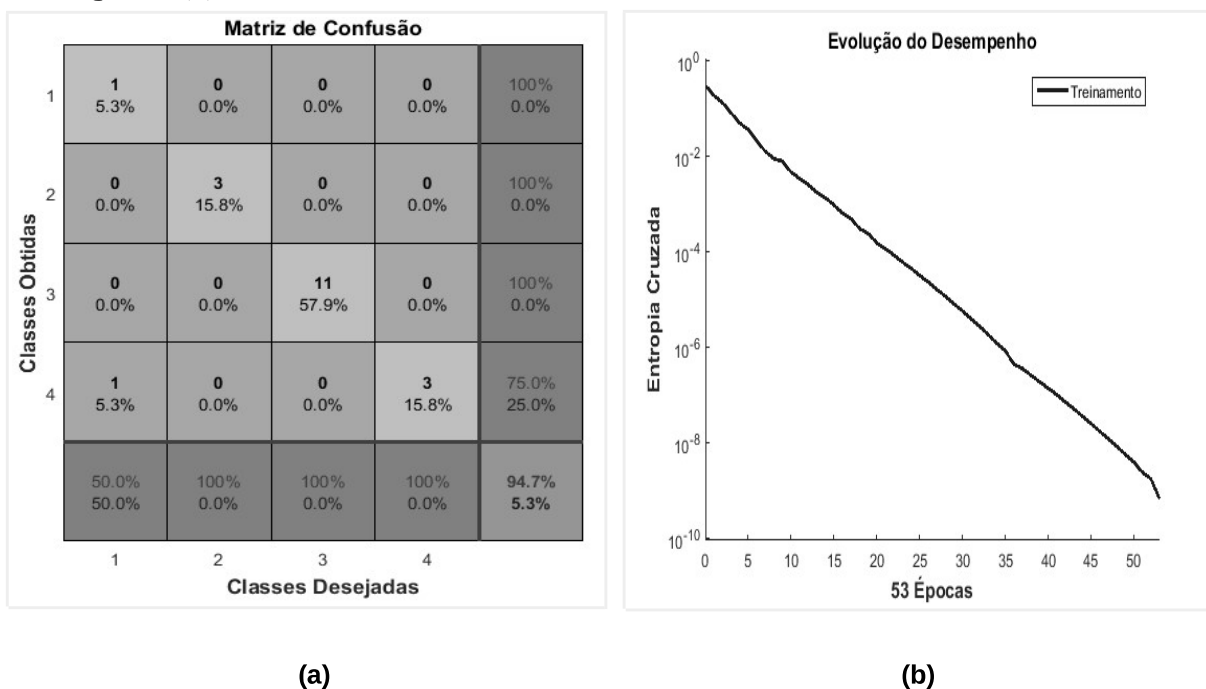


Figura 5: (a) Matriz de confusão no 2º caso, (b) Desempenho da rede PMC no 2º caso.

Conforme esperado, a eficiência de classificação da rede aumentou consideravelmente ao eliminar as classes que apresentavam poucas classificações no banco de dados, obtendo uma eficiência de quase 95 % com apenas um erro relacionado à classificação da classe 1 (classe 2 da Tabela 2), conforme ilustra a matriz de confusão.

7. Conclusão

Neste trabalho foi apresentado um método baseado em inteligência artificial para criar um sistema capaz de classificar corretamente crianças que necessitam que cuidados especiais com relação à autocuidados. A rede neural PMC foi aplicada a conjunto de dados referentes a limitações que algumas crianças com incapacidade físicas e motoras possuem de acordo com ICF-CY, dessa forma a rede PMC foi capaz de aprender um comportamento de classificação de acordo com os atributos de entrada.

A rede PMC foi aplicada considerando duas situações: na primeira delas todas as classes no banco de dados foram consideradas e na segunda somente 4 classes foram utilizadas, devido o baixo número de crianças classificadas nas demais classes. Os resultados obtidos mostraram que em ambos os casos foi possível obter uma boa acurácia na identificação das classes. O primeiro caso foi o que apresentou a menor acurácia com 85 %, já o segundo obteve 94,7 %, mostrando que devido a pequeno número de crianças identificadas em algumas classes prejudicaram a eficiência método, porém mesmo assim os resultados foram satisfatórios. Dessa forma a rede PMC trata-se de um bom método para classificação de autocuidados de crianças de acordo com suas incapacidades físicas e motoras, como é proposto pelo banco de dados SCADI, que possui somente a classificação de 70 crianças. Com aumento do banco de dados, principalmente com relação às classes que apresentam uma menor quantidade de classificação seria possível obter melhores resultados na classificação de todas as classes disponíveis. Em trabalhos futuros pretende-se aplicar outros métodos de aprendizado de máquina comumente utilizados em problemas de classificação, tais como KNN, *K-means* e diferentes redes neurais como a SVM e RBF, buscando atingir um melhor desempenho e que possibilitem uma melhor análise dos dados utilizados.

Referências

- CASTANEDA, Luciana; BERGMANN, Anke; BAHIA, Ligia. (2014) A Classificação Internacional de Funcionalidade, Incapacidade e Saúde: uma revisão sistemática de estudos observacionais, “Revista Brasileira de Epidemiologia”, São Paulo, v. 17, n. 2
- HERRMANN, K. *et al.* (2011) Differences in functioning of individuals with tetraplegia and paraplegia according to the International Classification of Functioning, Disability and Health (ICF). “Spinal Cord”, v. 49, n. 4.
- SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogerio Andrade. (2010) “Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático”. São Paulo: Artliber.
- WORLD HEALTH ORGANIZATION. (2007) International Classification of Functioning, Disability and Health. Version for Children and Youth. Geneva: World Health Organization.
- ZARCHI, M. S; FATERMI, B; DEGHANIZADEH M. (2018) 'SCADI: A standard dataset for self-care problems classification of children with physical and motor disability.' (2018) “International Journal of Medical Informatics”.