

Performance Analysis with Artificial Neural Networks, MLP and RBF Architectures for a Problem of Classification of Children with Autism

Análise de Desempenho com Redes Neurais Artificiais, Arquiteturas MLP e RBF para um Problema de Classificação de Crianças com Autismo

Rhyan Ximenes de Brito¹, Carlos Alexandre Rolim Fernandes², Márcio André Baima Amora³

¹ Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Tianguá, CE – Brasil

² Universidade Federal do Ceará (UFC)
Sobral, CE – Brasil

³ Universidade Federal do Ceará (UFC)
Sobral, CE – Brasil

rxbrito@gmail.com, alexandrefernandes@ufc.br, marcio@sobral.ufc.br

Abstract. *Artificial Neural Networks has been outstanding in solving problems in several areas. In this sense, a study was carried out with the implementation and analysis of the Multilayer Perceptron (MLP) and Radial Basis Function Neural Network (RBF) networks, in order to compare results based on training, test and classification of children with or without autism. The methodology was implemented based on 292 samples of individuals from a public database, using the Matlab tool R2015a, divided into 10 parts with cross validation. The results were analyzed considering the different characteristics and behaviors of the implemented networks, obtaining a measure of the quality reached.*

Keywords. *Analysis; Neural Networks; Autism.*

Resumo. *As Redes Neurais Artificiais tem-se destacado na resolução de problemas em diversas áreas. Nesse sentido realizou-se um estudo com a implementação e análise das redes Multilayer Perceptron (MLP) e Radial Basis Function Neural Network (RBF), objetivando comparar resultados baseados no treinamento, teste e classificação de crianças com ou sem autismo. A metodologia foi implementada com base em 292 amostras de indivíduos de um banco de dados público, através da ferramenta Matlab R2015a, divididas em 10 partes com validação cruzada. Os resultados foram analisados considerando as características e os comportamentos diferentes das redes implementadas, obtendo-se uma medida da qualidade atingida.*

Palavras-Chave. Análise; Redes Neurais; Autismo.

1. Introdução

O uso de Redes Neurais Artificiais tem-se destacado como mecanismo facilitador na resolução de problemas em diversas áreas. Nessa perspectiva realizou-se um estudo através da implementação e análise das redes MLP (*Multilayer Perceptron*) e RBF (*Radial Basis Function Neural Network*), com o objetivo de comparar os resultados baseados em procedimentos quantitativos, com ênfase no treinamento e teste, auxiliando na classificação de crianças com ou sem autismo.

Diante dessa perspectiva o autismo é visto como uma perturbação neurobiológica global do desenvolvimento que se inicia normalmente antes dos três anos de idade e tem por características principais dificuldades na socialização, na linguagem e no comportamento [Souza 2016].

Por outro lado a busca por diagnóstico é estritamente clínica, dessa forma a investigação sobre a identificação precoce do autismo representa uma prioridade na saúde pública. Além disso, um diagnóstico e tratamento precoce podem ter um impacto econômico positivo, tornando possível a redução de custos com tratamentos de pessoas com autismo [Souza 2016].

Este estudo busca implementar e analisar uma rede neural MLP (*Multilayer Perceptron*) e outra RBF (*Radial Basis Function Neural Network*), com o objetivo de comparar os resultados baseados em procedimentos quantitativos, com ênfase no treinamento das redes, de forma a auxiliar na classificação de indivíduos com ou sem autismo. A metodologia foi desenvolvida com base em um grupo de indivíduos do banco de dados público intitulado “*Autism-ScreeningChild-Data Plus Description*” obtido através do link, <https://archive.ics.uci.edu/ml/machine-learning-databases/00419/>. Os resultados foram obtidos através da implementação de duas redes neurais com características e comportamentos diferentes (MLP e RBF).

A motivação para este trabalho está relacionada à importância da aplicação de técnicas de Inteligência Artificial e Mineração de Dados em situações que possam auxiliar profissionais da área de saúde dando suporte de forma direta no diagnóstico de problemas como o autismo.

Este trabalho está organizado da seguinte forma: a Seção 2 apresenta alguns trabalhos relacionados, a Seção 3 o transtorno do espectro autista, a Seção 4 apresenta as redes neurais artificiais (MLP e RBF), a Seção 5 a metodologia utilizada, a Seção 6 os resultados e discussões e por fim, conclusões na Seção 7.

2. Trabalhos Relacionados

Esta seção apresenta um estado da arte sobre a utilização de Redes de Neurais que buscam por respostas a diferentes problemas pesquisados na área de TA (Tecnologias Assistivas), apresentando um resumo das abordagens a serem descritas.

[Pinheiro 2018] propôs a construção de um classificador que dada uma imagem facial de uma criança, conseguisse discriminar entre os dois grupos, com ou sem autismo, auxiliando assim no diagnóstico. Para testar a hipótese, foram coletadas imagens bidimensionais de crianças e adolescentes com autismo. As imagens foram

processadas, testadas e comparadas a diferentes métodos de redução de dimensionalidade e classificação, como resultado obteve-se uma acurácia de 80%.

Os estudos de [Vigneshwaran et al. 2013] apresentaram uma abordagem para o diagnóstico do autismo com base na utilização de imagens extraídas com RM (Ressonância Magnética) detectadas com VBM (Morfometria Baseada em *Voxel*) usando o algoritmo (PBL) *Projection Based Learning* para um classificador McRBFN (*Meta-cognitive Radial Basis Function Network*). Os exames utilizados foram obtidos do conjunto de dados do Centro Médico *Langone* da Universidade de Nova York que consiste em imagens de RM de 184 indivíduos. Entre eles, 79 foram diagnosticados com autismo, enquanto que 105 eram saudáveis. Entre os 79 diagnosticados com autismo, 53 tiveram diagnóstico de transtorno autista, 21 com transtorno de *Asperger* e 5 com transtorno invasivo do desenvolvimento.

[Thabtah 2018b] analisou criticamente estudos investigativos recentes sobre o autismo, não apenas articulando as questões de diagnósticos e prognósticos, mas a utilização de técnicas de aprendizado de máquina, como máquinas de vetores de suporte, árvores de decisão, regressões logísticas e outras, que foram aplicadas a conjuntos de dados relacionados ao autismo para construir modelos preditivos na previsão para melhorar a tomada de decisões.

[Abbas et al. 2017] propuseram a aplicação do Aprendizado de Máquina a dados clínicos padrão-ouro obtidos em milhares de crianças em risco de distúrbios do espectro do autismo. A ferramenta criada combina dois métodos de triagem em uma única avaliação, uma baseada em questionários curtos e estruturados relatados pelos pais e a outra baseada na marcação de comportamentos-chave de vídeos caseiros curtos e semiestruturados de crianças. O estudo demonstrou uma melhora significativa da precisão em relação a ferramentas de triagem padrão em uma amostra de estudo clínico de 162 crianças. Por fim discutiu-se o desafio de estender algoritmos de aprendizado de máquina a condições além do autismo.

[Thabtah 2017] trouxe uma proposta empregando aprendizado de máquina na classificação do autismo para discutir seus prós e contras. Além disso, destacando um problema notável associado as atuais ferramentas de triagem, com foco na confiabilidade usando o DSM-IV (*Diagnostic and Statistical Manual of Mental Disorders -IV*) em vez da nova classificação encontrada no manual do DSM-5. Daí tendo-se a necessidade de alterar as ferramentas de triagem atuais para refletir os novos critérios impostos pela classificação do autismo no DSM-5, particularmente os algoritmos de diagnóstico incorporados nesses métodos.

Nesta abordagem os autores propuseram a utilização do *App mobile AMP (Autism Management Platform)*, integrando informações de assistência médica para capturar, analisar e gerenciar dados associados ao diagnóstico e tratamento do autismo em crianças. Simplificando os meios pelos quais pais, responsáveis e médicos pudessem coletar e compartilhar dados multimídia uns com os outros, facilitando a comunicação e reduzindo a redundância de dados. Fornecendo uma plataforma de análise e interface *Web* inteligente permitindo que médicos e especialistas agregassem e extraíssem dados em tempo real, fornecendo *feedback* relevante de maneira que os dados pudessem ser aproveitados para orientação do tratamento [Linstead et al. 2016].

3. Transtorno do Espectro Autista

O TEA (Transtorno do Espectro Autista) é uma síndrome caracterizada pela dificuldade na interação social e desvios qualitativos na comunicação e no uso da imaginação, com o diagnóstico consistindo basicamente de avaliações clínicas [Carvalho et al. 2016]. Está intimamente relacionado a dificuldades de socialização, agressividade, interesse restrito por assuntos ou podem deter habilidade verbal e cognitiva desenvolvida, estas características variam de acordo com o quadro [Bentes et al. 2016].

Dessa forma os diagnósticos convencionais para o autismo exigem que os profissionais médicos conduzam uma avaliação clínica da idade de desenvolvimento do paciente com base em vários domínios (por exemplo, excessos de comportamento, comunicação, autocuidado, habilidades sociais) [Thabtah et al. 2018].

Para o autismo não há cura, o que pode ser feito são intervenções. A forma de tratamento com maior reconhecimento são os tratamentos baseados em um modelo comportamental, que possuem como característica definidora a ABA (Análise Experimental do Comportamento Aplicada), ciência dedicada à compreensão das leis pelas quais os eventos ambientais influenciam e modificam o comportamento [Gonçalves et al. 2017].

Deve-se salientar que a ABA requer uma avaliação cuidadosa de como os eventos ambientais interagem para influenciar o comportamento de um indivíduo. A avaliação consiste em fatores contextuais, como [Gonçalves et al. 2017]: (i) o cenário em que um comportamento ocorre; (ii) variáveis motivacionais como a necessidade de atingir um objetivo; (iii) eventos antecedentes que levam à ocorrência de um comportamento; (iv) consequências ou eventos que geram comportamentos recorrentes.

3.1. Classificação Atual Para o Transtorno do Espectro Autista

O autismo com o passar dos anos recebeu diversas denominações, contudo de acordo com o CDC (Centro de Controle e Prevenção de Doenças), existem 3 tipos de Autismo [Saudavel 2017]:

1. **Síndrome de Asperger:** É a forma mais leve, crianças que a possuem normalmente tornam-se extremamente obsessivas por um único objeto e pelo seu assunto preferido, possuem uma inteligência acima da média.
2. **Transtorno Invasivo do Desenvolvimento:** Um pouco mais grave do que a Síndrome de Asperger e um pouco mais leve do que o Transtorno Autista, com interação social prejudicada e menos comportamentos repetitivos.
3. **Transtorno Autista:** Possui sintomas mais rígidos do que os citados anteriormente, com o funcionamento da capacidade social, cognitiva e linguística bastante afetada, além de comportamentos repetitivos.

Porém 2 outros tipos foram anexados aos existentes, dessa vez pelo Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-V) [Saudavel 2017]:

1. **Síndrome de Rett:** Não está relacionada ao espectro autista, afetando em sua maioria crianças do sexo feminino. É caracterizada por comportamentos específicos como: parar de responder socialmente, torcer demais as mãos e perda de competências linguísticas.

2. **Transtorno Desintegrativo da Infância:** É o mais grave de todos e o menos comum, cerca de 2 a cada 100 mil crianças são diagnosticadas com esse transtorno. Pode-se dizer que depois de um período de desenvolvimento normal, geralmente entre 2 e 4 anos de idade, a criança perde de maneira muito brusca as habilidades sociais, linguísticas e intelectuais, definitivamente.

Além desses tipos apresentados, o Transtorno do Espectro Autista (TEA) também é dividido em graus conforme a Classificação DSM-V: Níveis de Gravidade do Espectro Autista [Saudavel 2017]:

1. **Nível 1 (Leve):** Com relação a comunicação social nesse nível apresentam as seguintes características: dificuldade para iniciarem uma interação social com outras pessoas; pouco interesse por interações sociais. No quesito comportamentos repetitivos e restritos apresentam: inflexibilidade comportamental que interfere diretamente no funcionamento de um ou mais contexto; dificuldade significativa em trocar de atividade; problemas de organização e planejamento são obstáculos à independência.
2. **Nível 2 (Médio):** Nesse nível a comunicação social apresenta: grave *déficit* nas habilidades sociais seja verbal ou não; prejuízos sociais mesmo quando recebem apoio; limitações para iniciar algum tipo de interação. Com relação aos comportamentos repetitivos e restritos possuem como características: inflexibilidade do comportamento; dificuldade em lidar com mudanças; comportamentos restritos ou repetitivos frequentes.
3. **Nível 3 (Grave):** Para a comunicação social apresentam como características: *déficits* graves na comunicação verbal e não verbal; dificuldade em iniciar uma interação social ou se abrir a alguma que parta de outras pessoas. Para comportamentos repetitivos e restritos: Possuem os mesmos comportamentos apresentados pelas crianças no nível 2.

4. Redes Neurais Artificiais

RNA (Rede Neural Artificial) é um modelo computacional biologicamente inspirado, constituído por elementos de processamento simples (neurônios artificiais) que aplicam uma determinada função matemática aos dados (função de ativação) gerando uma única resposta, dispostos em camadas e ligados entre si, sendo estas conexões geralmente associadas a coeficientes denominados pesos [Braga, Carvalho and Ludemir, 2007].

4.1 *Multilayer Perceptron* (MLP)

Uma Rede Neural Artificial (RNA) do tipo MLP consiste de um conjunto de unidades (nós ou neurônios), que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída, onde o sinal de entrada se propaga pela RNA camada por camada [Ferreira et al. 2016]. Na Figura 1 é apresentada a estrutura básica de uma RNA do tipo MLP.

As redes neurais artificiais MLP normalmente são utilizadas em problemas de classificação, de aproximação (ou análise de regressão) o que inclui previsão e modelagem de séries temporais em áreas como: controle, diagnóstico e *data mining* [Ferreira et al. 2016].

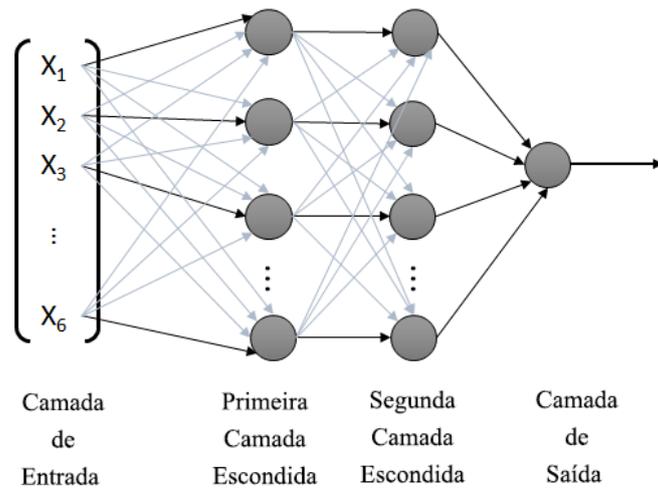


Figura 1. Multilayer Perceptron (MLP)

4.2 Radial Basis Function Neural Network (RBF)

A estrutura típica de uma rede de função de base radial é composta por uma camada de entrada que está associada diretamente às informações de entrada da rede, uma única camada escondida constituída por funções de ativação de base radial que realizam uma transformação não linear do espaço de entrada e uma camada de saída linear que fornece a resposta ao padrão aplicado nas entradas da rede [Reis 2014].

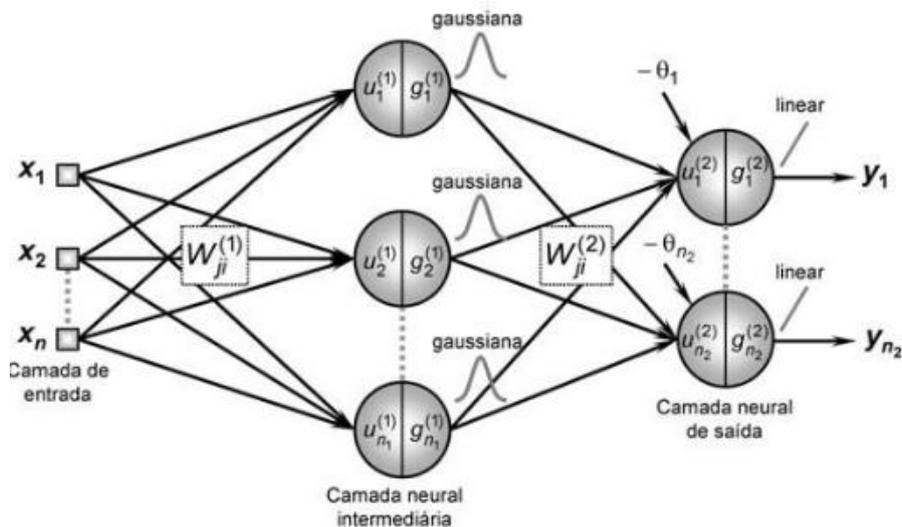


Figura 2. Rede Radial Basis Function Neural Network (RBF)

A Figura 2 ilustra a estrutura básica de uma rede RBF. Deve-se salientar que assim como as redes MLP, as RBF também são empregadas para aproximação de funções e classificação de padrões em espaços com dimensão muito grande. Os neurônios de saída executam uma combinação linear das funções bases computadas pelos neurônios da camada intermediária [Nakai et al. 2015].

5. Metodologia

A abordagem proposta para o estudo realizado está fundamentada principalmente na noção de redes neurais artificiais, *Data mining* e classificação através da utilização das redes MLP e RBF.

O fluxo da metodologia neste projeto foi desenvolvido em 3 etapas: (1) preparação da base de dados e ferramenta utilizada; (2) treinamento; e (3) teste com a base de dados utilizando as redes MLP e RBF, nessa ordem.

5.1 Preparação da Base de Dados e Ferramenta Utilizada

Para a implementação dos algoritmos utilizou-se a ferramenta *Matlab R2015a* e um banco de dados público intitulado "Autism-ScreeningChild-Data Plus Description" obtido através do link: <https://archive.ics.uci.edu/ml/machine-learning-databases/00419/>, composto por 292 amostras, que foram avaliadas com relação a 19 atributos. Salienta-se que na base de dados existem 151 amostras de crianças não autista, representando cerca de 51,71% do total de amostras e 141 amostras de crianças autistas o que equivale a 48,28%.

5.2 Treinamento e Teste

Vale lembrar que todos os dados da camada de entrada foram normalizados e balanceados. Para o treinamento e teste utilizou-se de validação cruzada (*cross validation*) e a técnica do *k-fold*, dividindo-se a base de dados em 10 partes, onde 9 foram utilizadas para treinamento e 1 para teste, de maneira que fossem feitos 10 treinamentos com 10 testes, ressaltando-se que a divisão ao final ficou com a seguinte configuração, 9 amostras com 29 crianças e 1 amostra com 31 crianças. Em vista disso o *k-fold* foi balanceado de forma que cada uma das 10 amostras recebessem uma média de 15 crianças autistas e 14 não autistas. As subseções a seguir descrevem com mais detalhes o processo utilizado para treinamento e teste com as arquiteturas de redes neurais artificiais citadas (MLP e RBF). Para cada um dos 10 treinamentos foi criada uma matriz de confusão, representando os valores reais e os valores preditos pelo classificador.

5.2.1 Treinamento e Teste com a Base de Dados Utilizando a Rede MLP

A Figura 3 mostra a arquitetura da rede MLP utilizada, com 18 neurônios de entrada, 2 camadas ocultas com 10 neurônios cada e uma camada de saída com 2 neurônios. Para o treinamento da rede MLP utilizou-se 20.000 *epochs*.

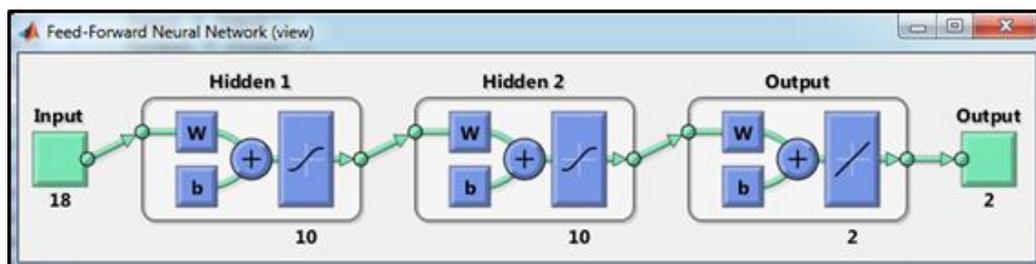


Figura 3. Arquitetura da Rede Neural MLP

Conforme descrito na Tabela 1, outras configurações foram utilizadas para treinamento e teste, todas com 18 neurônios na camada de entrada e 2 neurônios na camada de saída, porém a que obteve os melhores resultados foi a configuração descrita na Figura 3.

A escolha da configuração foi embasada no desempenho, visto que entre as configurações testadas, as que possuíam duas camadas ocultas com 10 neurônios obtiveram as melhores acurácias, outro ponto observado foi o número de *epochs*, na medida que eram aumentadas, maiores eram os acertos obtidos pela rede, chegando ao ponto de saturação (100% de acertos).

Tabela 1. Testes com Diferentes Arquiteturas na Rede Neural MLP

Testes	Camada Oculta	Camada de Saída	Epochs	Melhor Acurácia
1°	1 Camada (10 neurônios)	1 Camada (2 neurônios)	2.000	87,1%
2°	2 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	2.000	89,7%
3°	3 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	2.000	82,8%
4°	1 Camada (10 neurônios)	1 Camada (2 neurônios)	10.000	95,6%
5°	2 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	10.000	96,7%
6°	3 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	10.000	93,1%
7°	1 Camada (10 neurônios)	1 Camada (2 neurônios)	15.000	86,2%
8°	2 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	15.000	93,1%
9°	3 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	15.000	82,9%
10°	1 Camada (10 neurônios)	1 Camada (2 neurônios)	20.000	96,6%
11°	2 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	20.000	100%
12°	3 Camadas (10 neurônios cada)	1 Camada (2 neurônios)	20.000	93,1%

5.2.2 Treinamento e Teste com a Base de Dados Utilizando a Rede RBF

A Figura 4 mostra a arquitetura da rede neural artificial RBF utilizada no estudo, com uma camada de entrada com 10 neurônios e uma camada de saída com 2 neurônios.

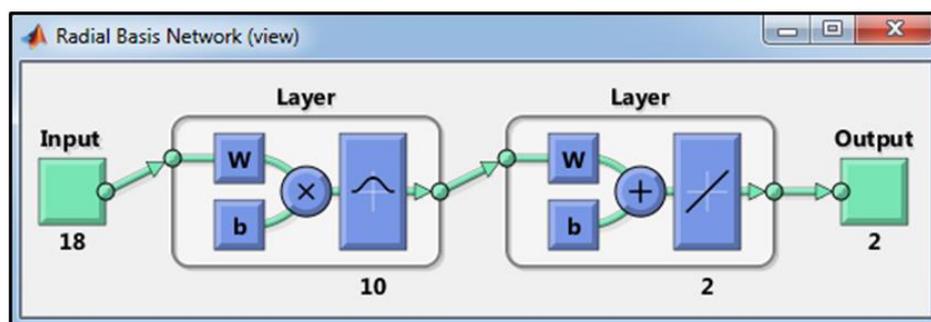


Figura 4. Arquitetura da Rede Neural RBF

Na Tabela 2 são exibidas várias configurações utilizadas para treinamento e teste, observando-se que a configuração descrita na Figura 4 foi a que obteve os melhores resultados.

Para a escolha da configuração, o desempenho foi o fator principal, visto que várias configurações foram testadas, observando que a medida que aumentava-se a quantidade de neurônios na camada de entrada maiores eram as acurácias conforme descrito na Tabela 2, contudo observou-se que houve um ponto de saturação (93,1%).

Tabela 2. Testes com Diferentes Arquiteturas na Rede Neural RBF

Testes	Camada de Entrada	Camada de Saída	Melhor Acurácia
1º	1 Camada (1 neurônio)	1 Camada (2 neurônios)	72,4%
2º	1 Camada (5 neurônios)	1 Camada (2 neurônios)	82,8%
3º	1 Camada (8 neurônios)	1 Camada (2 neurônios)	86,6%
4º	1 Camada (9 neurônios)	1 Camada (2 neurônios)	91,3%
5º	1 Camada (10 neurônios)	1 Camada (2 neurônios)	93,1%
6º	1 Camada (15 neurônios)	1 Camada (2 neurônios)	90,3%
7º	1 Camada (20 neurônios)	1 Camada (2 neurônios)	89,7%
8º	1 Camada (25 neurônios)	1 Camada (2 neurônios)	86,2%
9º	1 Camada (30 neurônios)	1 Camada (2 neurônios)	87,8%
10º	1 Camada (35 neurônios)	1 Camada (2 neurônios)	85,6%

6. Resultados e Discussões

Os resultados foram obtidos com base em dois pontos da investigação: treinamento e teste com as redes neurais artificiais MLP e RBF com percentuais de acurácia bastantes significativos e na discussão dos resultados obtidos através das 10 amostras do *data set* utilizado. É importante ressaltar que tanto a rede MLP quanto a RBF obtiveram resultados satisfatório para o melhor e o pior caso de forma geral, ressaltando que o pior caso em ambas as arquiteturas obtiveram o mesmo percentual de acertos e erros. Entretanto a rede neural MLP obteve melhores resultados que a rede neural artificial RBF de forma geral.

6.1 Treinamento

A Figura 5 mostra a matriz de confusão resultante do treinamento, com o melhor caso entre os 10 do *k-fold*, com 100% de acertos e 0% erro para a rede neural MLP, onde a linha 1 da matriz representa as crianças não autistas (15) e a linha 2 as crianças com autismo (14), de uma amostra de 29 crianças.

Output Class	1	15 51.7%	0 0.0%	100% 0.0%
	2	0 0.0%	14 48.3%	100% 0.0%
		1	2	
		Target Class		

Figura 5. Melhor Caso Para MLP

Por outro lado a Figura 6 mostra o pior caso entre os 10 utilizados no estudo, com 72,4% de acertos para 27,6% de erros adquiridos durante o processo de treinamento e teste para uma amostra de 15 crianças não autista e 14 autistas na rede MLP.

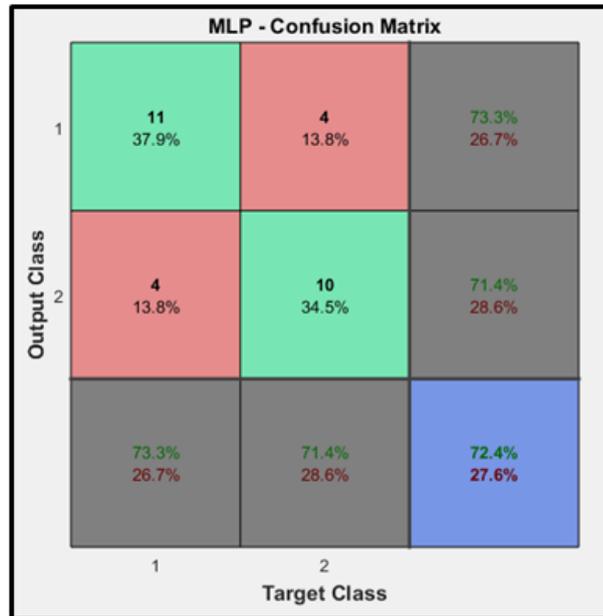


Figura 6. Pior Caso Para MLP

Logo abaixo tem-se a Figura 7 mostrando a matriz de confusão da rede neural RBF com o melhor caso entre os 10 do *k-fold* com 93,1% de acertos e 6,9% de erros durante o treinamento. A linha 1 da matriz representa as crianças não autistas (15) e a linha 2 as crianças com autismo (14). Isso mostra que o resultado aproximou-se de 100% de acertos.

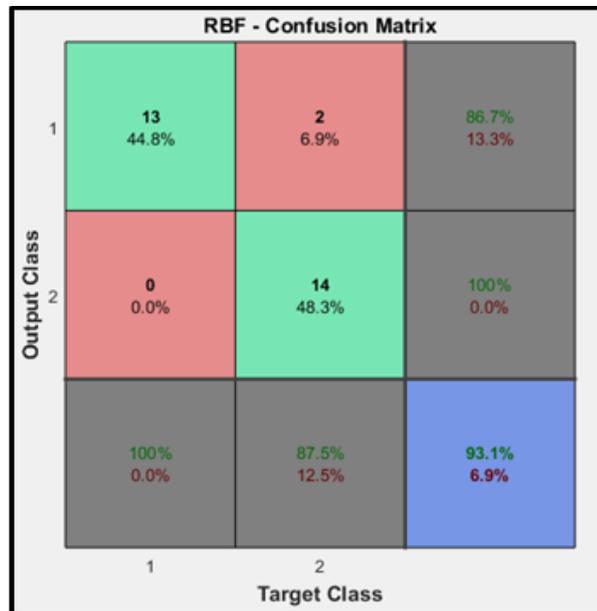


Figura 7. Melhor Caso Para RBF

Por outro lado a Figura 8 mostra a matriz de confusão com o pior caso com 72,4% de acertos e 27,6% de erros adquiridos durante o processo de treinamento com a rede neural RBF. Vale ressaltar que o resultado do pior caso na rede RBF atingiu coincidentemente o mesmo resultado que na MLP, ambas ficando distantes dos 100% de acertos.

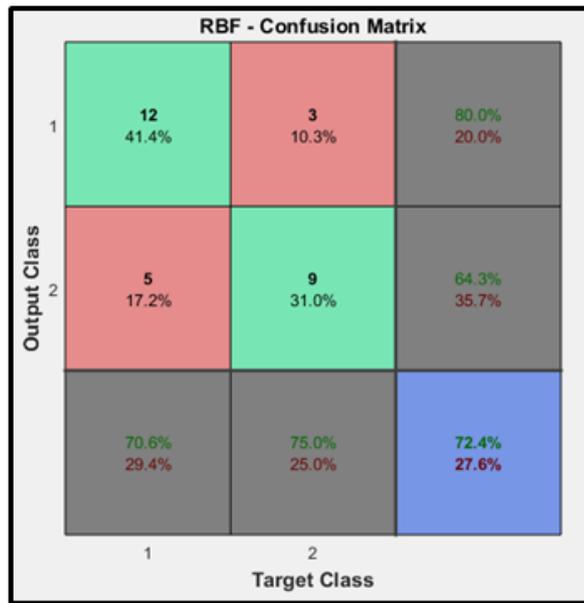


Figura 8. Pior Caso Para RBF

Na Figura 9 tem-se a matriz de confusão gerada a partir do treinamento feito com todo o *data set* e testado com o melhor *fold* obtido na rede MLP que obteve 100% de acertos para a amostra utilizada. Nela observa-se que o percentual de acertos foi de 85,6% acertos e 14,4% de erros alcançados com a mesma configuração utilizada na amostra de melhor resultado. Mediante o exposto nota-se que esses resultados encontram-se próximos do caso médio obtido na rede MLP e na RBF.

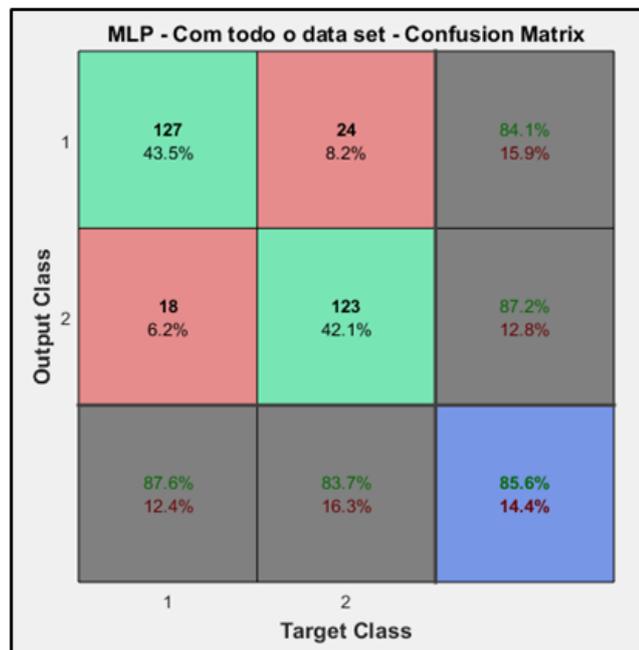


Figura 9. Treino com o *dataset*, teste com o melhor *fold* (MLP)

A Figura 10 mostra a matriz de confusão com os resultados obtidos utilizando toda a base de dados para o treino e o melhor caso para o teste com 86,6% de acertos e 13,4% de erros. Dessa forma a rede neural RBF conseguiu resultados melhores que a

MLP. Esses resultados não foram esperados tomando como base o fato da rede neural MLP possuir o melhor caso médio e o melhor caso, com base nos percentuais de acertos e erros.

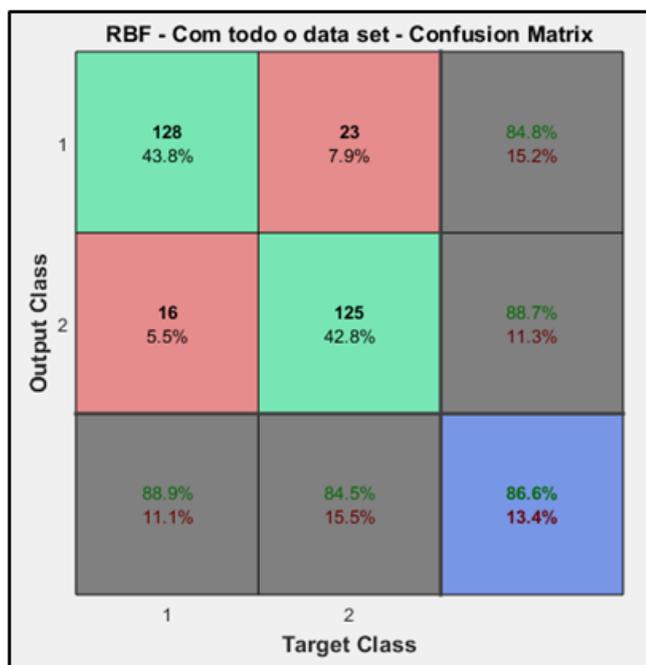


Figura 10. Treino com o *dataset*, teste com o melhor *fold* (RBF)

Vale lembrar que a base de dados utilizada nesse estudo, foi implementada por [Thabtah 2018a] que propôs a utilização de classificadores derivados usando algoritmos de aprendizado de máquina onde obtiveram resultados com acurácia de 94,23% com *Logistic Regression* e 91,34% com *Naïve Bayes* para dados relacionados a adolescentes, para adultos 99,85% com *Logistic Regression* e 95,73% com *Naïve Bayes* e por fim 97,94% com *Logistic Regression* e 92,80% com *Naïve Bayes* para dados de crianças. Contudo no estudo em questão pode-se perceber que a rede neural MLP obteve 100% de acertos se comparado com os resultados obtidos pelos classificadores utilizados pelo autor citado.

Tabela 3. Tabela Comparativa (Métodos Utilizados e Acurácias)

Método Utilizado	Acurácia (%)	Fase da Vida
<i>Logistic Regression</i>	97,94	Crianças
<i>Naïve Bayes</i>	92,80	Crianças
<i>Logistic Regression</i>	94,23	Adolescentes
<i>Naïve Bayes</i>	91,34	Adolescentes
<i>Logistic Regression</i>	99,85	Adultos
<i>Naïve Bayes</i>	95,73	Adultos
<i>MLP</i>	100	Crianças
<i>RBF</i>	93,10	Crianças

A Tabela 3 mostra um comparativo entre os classificadores utilizados pelos autores do trabalho (MLP e RBF) e os demais métodos utilizados pelo autor [Thabtah 2018a]. Interessante notar que o resultado obtido pela MLP em relação os demais observados foi de 100% de acertos.

Tabela 4. Tabela Comparativa Trabalhos Relacionados

Método Utilizado	Acurácia (%)	Fase da Vida
<i>Logistic Regression</i>	97,94	Crianças
<i>Naive Bayes</i>	92,80	Crianças
<i>Logistic Regression</i>	94,23	Adolescentes
<i>Naive Bayes</i>	91,34	Adolescentes
<i>Logistic Regression</i>	99,85	Adultos
<i>Naive Bayes</i>	95,73	Adultos
<i>MLP</i>	100	Crianças
<i>RBF</i>	93,10	Crianças
<i>Random Florests</i>	80	Crianças
<i>PBL-McRBFN</i>	78	Crianças/adolescentes/Adultos
<i>SVM</i>	74	Crianças/adolescentes/Adultos
<i>Random Florests</i>	74	Crianças/adolescentes/Adultos
<i>Random Florest</i>	95	Crianças

A Tabela 4 traz um comparativo entre os métodos e as acurácias encontradas pelos autores citados na Seção 2 desse artigo e os resultados obtidos com os métodos MLP e RBF pelos autores deste trabalho, com destaque para rede neural MLP que obteve 100% de acerto.

6.2 Teste

A Tabela 5 traz os resultados obtidos através dos testes realizados com a base de dados na arquitetura MLP, nela evidencia-se que o *fold* 02 obteve o melhor resultado com 100% de acertos, o *fold* 05 o pior resultado com 72,4% de acertos, e entre os 10 *folds* a média de acertos foi de 86,26 % para 13,74 % de erros.

Tabela 5. Tabela com Resultados dos Testes (MLP)

Rede Neural MLP			
K-fold	Taxa de Acerto Geral (%)	Taxa de Erro Geral (%)	Situação
01	93,5	6,5	
02	100	0	Melhor Caso
03	82,8	17,2	
04	93,1	6,9	
05	72,4	27,6	Pior Caso
06	75,9	24,1	
07	86,2	13,8	
08	82,8	17,2	
09	89,7	10,3	
10	86,2	13,8	
Total	86,26	13,74	Médio Caso

A seguir tem-se a Tabela 6 com os resultados obtidos através dos testes realizados com a base de dados com a rede neural RBF, nela evidencia-se que o *fold* 01 obteve o pior resultado com 72,4% de acertos, no *fold* 02 o melhor resultado obtido com 93,1% de acertos e entre os 10 *folds* a média de acertos foi de 83,12% e 16,88% de erros. De acordo com a tabela pode-se perceber que o caso médio obteve um percentual próximo do melhor caso adquirido na rede neural RBF.

Tabela 6. Tabela com Resultados dos Testes (RBF)

Rede Neural RBF			
K-fold	Taxa de Acerto Geral (%)	Taxa de Erro Geral (%)	Situação
01	72,4	27,6	Pior Caso
02	93,1	6,9	Melhor Caso
03	74,2	25,8	
04	91,3	8,7	
05	82,8	17,2	
06	79,3	20,7	
07	89,7	10,3	
08	82,8	17,2	
09	75,9	24,1	
10	89,7	10,3	
Total	83,12	16,88	Médio Caso

7. Conclusões

Este artigo relatou a utilização de redes neurais artificiais como ferramentas de aprendizagem de máquina abordando a problemática do autismo como um problema de classificação de dados com base em um *data set* composto por 292 amostras de crianças com e sem autismo. Nesse sentido realizou-se um estudo com a implementação e análise das redes *Multilayer Perceptron* (MLP) e *Radial Basis Function Neural Network* (RBF), objetivando comparar resultados baseados no treinamento e teste entre as duas redes neurais citadas e com outros trabalhos que utilizaram bases de dados iguais ou similares.

Nele puderam ser analisados criticamente os resultados dos dados normalizados e balanceados utilizando as estratégias *cross validation* e *k-fold*, ou seja, 10 amostras, onde nove eram para treinamento e uma para teste, comprovando-se que a utilização de aprendizagem de máquina pode ser um importante instrumento na triagem clínica de várias doenças inclusive de transtornos como o autismo. Apesar dos resultados terem sido satisfatórios não são conclusivos, pois outros classificadores podem ser implementados com a possibilidade de obterem resultados com igual importância.

Como trabalho futuro, sugere-se a implementação de outros classificadores como o KNN, LDA, QDA, usando as estratégias, *hold-out com subsampling* (20 execuções) e a *leave-one-out*, em seguida fazer um comparativo dos resultados encontrados com os encontrados nesse trabalho.

Referências

- Abbas, H., Garberson, F., Glover, E., and Wall, D. P. (2017). Machine learning for early detection of autism (and other conditions) using a parental questionnaire and home video screening. In *Big Data (Big Data)*, 2017 IEEE International Conference on, pages 3558–3561. IEEE.
- Bentes, C. C. A., BARBOSA, D. C., FONSECA, J. R. M., and BEZERRA, L. C. (2016). A família no processo de inclusão social da criança e adolescente com autismo: Desafios na sociedade contemporânea. *Intertem@ s Social* ISSN 1983-4470, 11(11).
- Braga, A. de P.; Carvalho, A. P. de L. F. de; Ludemir, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. 2 ed. Rio de Janeiro: LTC, 2007. 260p
- Carvalho, S. P., Lima, A. M., Brentani, H. P., Brunoni, D., Fock, R. A., and Nunes, F. L. S. (2016). Uma contribuição ao auxílio do diagnóstico do autismo a partir do processamento de imagens para extração de medidas antropométricas. *Revista de Informática Teórica e Aplicada*, 23(2):100–123.
- Ferreira, A., Ferreira, R. P., da Silva, A. M., Ferreira, A., and Sassi, R. J. (2016). Um estudo sobre previsão da demanda de encomendas utilizando uma rede neural artificial. *Blucher Marine Engineering Proceedings*, 2(1):353–364.
- Gonçalves, P. d. C. et al. (2017). Transtorno do espectro autista: protocolo de intervenção para pais em contexto ambulatorial.
- Linstead, E., Burns, R., Nguyen, D., and Tyler, D. (2016). Amp: A platform for managing and mining data in the treatment of autism spectrum disorder. In

- Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the, pages 2545–2549. IEEE.
- Nakai, M., Junior, H. G., Aguiar, P., Bianchi, E., and Spatti, D. (2015). Neural tool condition estimation in the grinding of advanced ceramics. *IEEE Latin America Transactions*, 13(1):62–68.
- Pinheiro, T. D. (2018). Classificação de imagens faciais para o auxílio ao diagnóstico do transtorno do espectro autista. PhD thesis, Universidade de São Paulo.
- Reis, F. A. (2014). Procedimento de ajuste de parâmetros de redes rbf via pso.
- Saudavel, R. M. (2017). O que é autismo, sintomas, tipos (infantil, leve) e mais. [Online; acessado em: 17-novembro].
- Souza, L. L. d. (2016). Análise da pressão plantar da marcha de autistas por dinâmica simbólica otimizada por algoritmo genético.
- Thabtah, F. (2017). Autism spectrum disorder screening: machine learning adaptation and dsm-5 fulfillment. In *Proceedings of the 1st International Conference on Medical and Health Informatics 2017*, pages 1–6. ACM.
- Thabtah, F. (2018a). An accessible and efficient autism screening method for behavioural data and predictive analyses. *Health informatics journal*, page 1460458218796636.
- Thabtah, F. (2018b). Machine learning in autistic spectrum disorder behavioral research: A review and ways forward. *Informatics for Health and Social Care*, pages 1–20.
- Thabtah, F., Kamalov, F., and Rajab, K. (2018). A new computational intelligence approach to detect autistic features for autism screening. *International journal of medical informatics*, 117:112–124.
- Vigneshwaran, S., Mahanand, B., Suresh, S., and Savitha, R. (2013). Autism spectrum disorder detection using projection based learning meta-cognitive rbf network. In *Neural Networks (IJCNN), The 2013 International Joint Conference on*, pages 1–8. IEEE.