

## Original

### Estudo da avaliação de redes neurais para a classificação do nível de lesão em acidentes de trânsito

Study of the evaluation of neural networks for the classification of the level of injury in traffic accidents

Ing. Randy Verdecia-Peña, Estudante Mestre, Pontifícia Universidade Católica do Rio de Janeiro, [randy.verdecia@cetuc.puc-rio.br](mailto:randy.verdecia@cetuc.puc-rio.br), Brasil

MSc. Rainel Sánchez-Pino, Pontifícia Universidade Católica do Rio de Janeiro, [rainel@cetuc.puc-rio.br](mailto:rainel@cetuc.puc-rio.br), Brasil

Recebido: 12/07/2018 Acetado: 23/14/11/2018

#### Resumo

Neste artigo é desenvolvida e estudado a modelagem de três redes neurais, MLP, RBF e PNN. O objetivo deste trabalho é o estudo da avaliação de redes neurais para classificar o nível de lesão de passageiros de veículos envolvidos em acidentes de trânsito. São empregados vários métodos que permitirão a profundização teórico-prático. Na pesquisa toma-se como campo de ação as informações sobre todas as pessoas envolvidas em acidentes de carro nas estradas dos EUA durante o ano 2001. Descrevem-se os parâmetros utilizados para a redes neurais modeladas. Uma análise comparativa destas redes foi feita de modo a fornecer o melhor desempenho na classificação do problema analisado. Conclua-se que o estudo garante avaliar o desempenho das redes empregadas.

**Palavras chaves:** classificação; redes neurais artificiais; classes desbalanceadas; desempenho

#### Abstract

In this article, the modeling of three neural networks, MLP, RBF and PNN is developed and studied. The objective of this work is the study of the evaluation of neural networks to classify the level of passenger injury of vehicles involved in traffic accidents. Several methods are used that will allow theoretical-practical deepening. In the research, the information about all people involved in car accidents on US roads during the year 2001 is taken as the field of action. The parameters used for neural networks are modeled. A comparative analysis of these networks was done in order to provide the best performance in the classification of the analyzed problem. It is concluded that the study guarantees to evaluate the performance of the networks used.

**Keywords:** classification; artificial neural networks; unbalanced classes; performance

## **Introdução**

O transporte rodoviário proporciona benefícios tanto para nações como para indivíduos, facilitando o movimento de bens e pessoas. Permite maior acesso a empregos, mercados econômicos, educação, recreação e assistência médica, os quais, por sua vez, têm impactos positivos diretos e indiretos sobre a saúde das populações. No entanto, o aumento do transporte rodoviário também colocou uma carga considerável na saúde das pessoas, na forma de lesões no trânsito.

De acordo com o Global Burden of Disease Project para 2004, os acidentes de trânsito causaram mais de 1,27 milhões de mortes nesse ano, um número semelhante ao causado por muitas doenças transmissíveis (WH, 2008). Lesões no trânsito afetam todos os grupos etários, mas seu impacto é mais notável entre os jovens.

Enquanto as taxas de mortes no trânsito em muitos países de alta renda se estabilizaram ou diminuíram nas últimas décadas, os dados sugerem que na maioria das regiões do mundo a epidemia global de lesões causadas pelo trânsito ainda está aumentando. Estima-se que, a menos que sejam tomadas medidas imediatas, as mortes nas estradas serão a quinta causa de morte para o ano 2030, resultando em uma estimativa de 2,4 milhões de mortes por ano (WH,2008), (WHS, 2008).

Além das fatalidades, muitas lesões menos graves são causadas por acidentes de trânsito: estima-se que entre 20 e 50 milhões de lesões não fatais ocorram anualmente ao redor do mundo (JL Murray, D Lopez, Mathers, & Stein, 2001), (Peden, 2004). Os desenvolvimentos e análises neste artigo visam fornecer a classificação do nível de lesão de passageiros de veículos envolvidos em acidentes de trânsito. Diferentes redes são testadas com base nas informações sobre todas as pessoas envolvidas em acidentes de carro nas estradas dos EUA durante o ano de 2001. O objetivo da investigação é o estudo da avaliação de redes neurais para classificar o nível de lesão de passageiros de veículos envolvidos em acidentes de trânsito e avaliar qual rede tem melhor desempenho.

## **População e amostra**

Na pesquisa, utilizaram-se métodos teóricos de conhecimento. A análise e síntese permitiram avaliar e resumir a informação disponível sobre o problema em estudo, a indução-dedutiva foi utilizada para estabelecer generalizações com base na análise das teorias, tendências e critérios de profissionais que aplicaram essas tecnologias; além do raciocínio e integração das informações obtidas no processo de pesquisa e chegando a obter o modelo desejado.

Finalmente, a abstração e a concreção foram usadas para refletir e reproduzir as qualidades, regularidades, regularidades estáveis e necessárias da pesquisa.

Seguindo a lógica da pesquisa, em primeira instancia foi feito uma descrição das redes neurais artificiais e a Descrição da Base de Dados que será utilizada e caracterização do Problema de Classes Desbalanceadas são descritos em população e amostra, logo foi testada a precisão das diferentes redes neurais, para várias configurações de redes e utilizando-se diferentes métodos de balanceamento de classes.

### Redes Neurais Artificiais

As Redes Neurais Artificiais são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental. Devido à sua semelhança com a estrutura do cérebro, ele poderia aprender por experiência os algoritmos para uma determinada tarefa e generalizar seu conhecimento obtido pelos exemplos anteriores (Velasco, 2018).

O elemento básico de processamento de uma rede neural apresentado na Figura 1 é composto do vetor de pesos  $W_j = (W_{1j}, \dots, W_{nj})$  equivalentes às conexões sinápticas em um neurônio real. A função  $\varphi$  é a função de ativação e  $\varphi_j$ (bias) é o limite de ativação. O vetor  $X = (X_1, \dots, X_n)$  corresponde à entrada e  $O_j$  à saída.

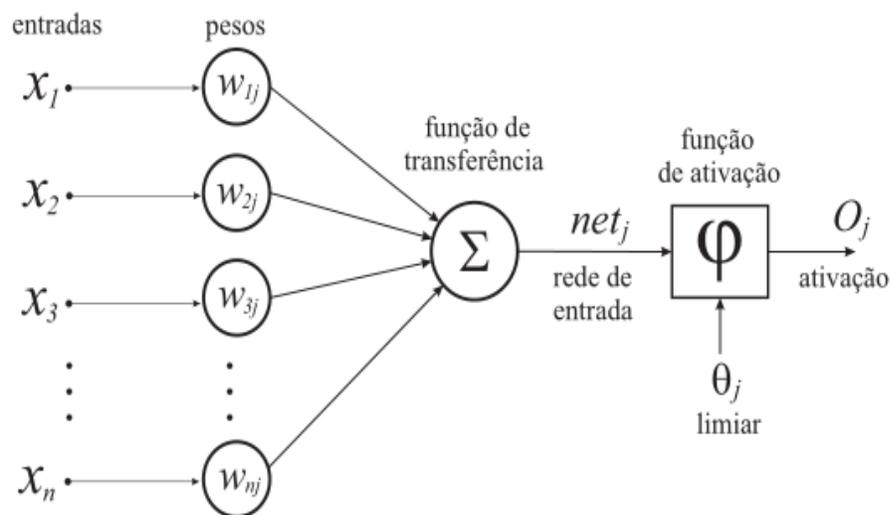
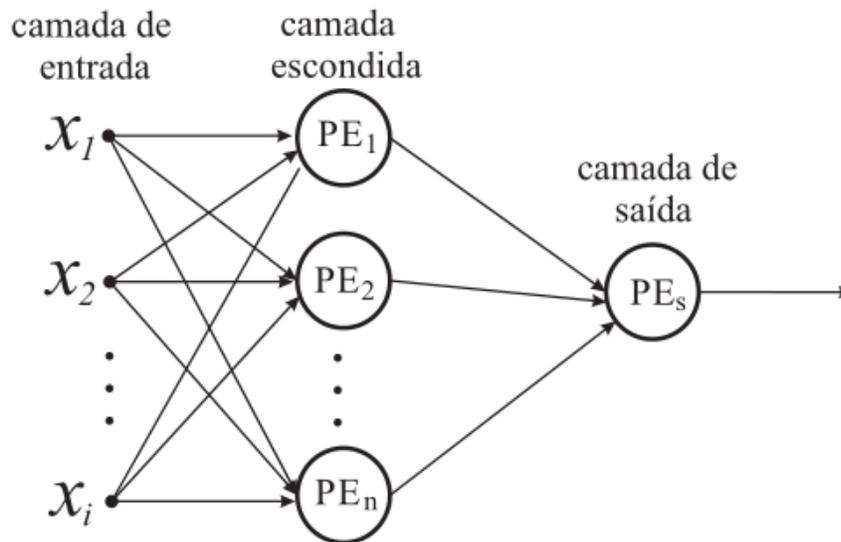


Fig. 1 Elemento processador de uma rede neural

#### A. Redes Multi-Layer Perceptron

As redes MLP (Multi-Layer Perceptron) são redes neurais de topologia feed-forward que contêm os nós de entrada (input layer), uma ou mais camadas escondidas (hidden layer) e uma camada

de saída (output layer). As camadas estão constituídas por neurônios (processadores) que têm capacidades computacional, a estrutura de uma rede MLP é apresentada na Figura 2



**Fig. 2 Rede MLP de uma camada escondida**

O número de neurônios na camada de saída é determinado pela dimensionalidade requerida da resposta desejada. Para a escolha do número de camadas escondidas e o número de neurônios da mesma, não há regras definidas. Estes dois aspectos determinam a complexidade da rede. As funções de ativação dos neurônios devem ser não-lineares e diferenciáveis. A não linearidade serve para separar padrões que não são linearmente separáveis e a diferenciação permite o cálculo do gradiente decrescente da função, direcionando assim o ajuste dos pesos do neurônio durante o treinamento. A especificação dos pesos sinápticos que interconectam os neurônios nas diferentes camadas da rede envolve a utilização de algoritmos de treinamento supervisionado. O algoritmo de treino mais utilizado nestas redes é o algoritmo backpropagation, baseado no aprendizado por correção de erro (Bonifácio, 2010).

#### *B. Redes Multi-Layer Perceptron*

As Redes RBF (Radial Basis Function Network) também estão constituídas de várias camadas e utilizam aprendizado supervisionado. Sua principal característica é a utilização de funções de base radial em todos os nós da camada oculta, que, ao invés de utilizar como argumento de função o produto escalar entre os valores do registro de entrada e os valores do registro de pesos do neurônio, utiliza a distância entre os vetores de entrada e seu centro (Carvalho, 2000). Como a rede MLP, a rede RBF é uma das RNAs que têm sido aplicadas com sucesso em muitas tarefas de classificação. A rede RBF na sua forma mais básica é apresentada na Figura 3, consiste de uma camada de entrada, apenas uma camada oculta, que aplica uma

transformação não-linear do espaço de entrada para um espaço de alta dimensionalidade, e a camada de saída, que aplica uma transformação linear no espaço fornecendo uma saída para a rede (Carvalho, 2000). Além disto, as redes RBF também são do tipo feedforward e completamente conectadas.

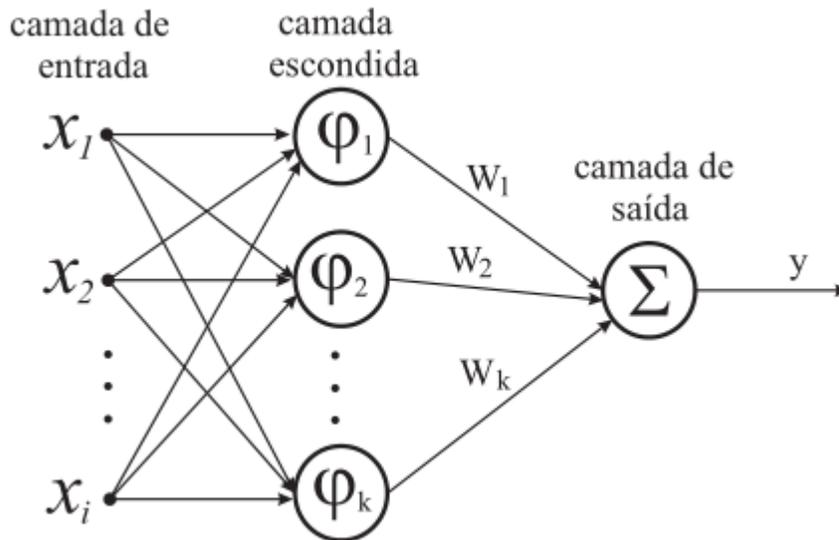


Fig. 3 Estrutura de uma rede RBF

### C. Redes PNN

As PNN (Probabilistic Neural Networks) são redes neurais inspiradas pelos classificadores bayesianos, realizam a aproximação de um Bayes ideal sob as condições de um conjunto de treinamento grande o suficiente. Estas redes neurais são compostas por duas camadas escondidas: uma denominada camada de padrão que terá um processador para cada vetor de entrada e sua ativação será uma forma de função que dimensiona as variáveis não-linearmente e outra denominada camada de soma que calcula a soma de todos os processadores de uma determinada classe. A camada de saída calcula a decisão de pertencer a qualquer das classes. Os pesos são designados, não são treinados e os pesos existentes nunca serão alternados, e somente novos vetores são inseridos nas matrizes de peso com o treinamento. A Figura 4 mostra a estrutura de uma rede PNN.

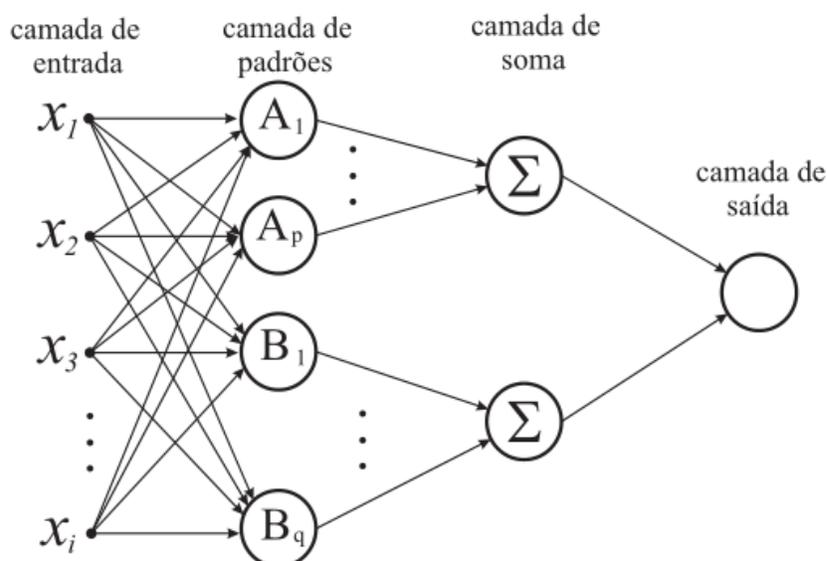


Fig. 4 Estrutura de uma rede PNN

#### Descrição da Base de Dados e caracterização do Problema de Classes Desbalanceadas

Tecnicamente qualquer conjunto de dados que apresenta uma desigualdade da distribuição entre as classes pode ser considerada desbalanceada. Não é raro o desbalanceamento entre as classes serem da ordem de 100:1, 1000:1 e 10000:1 onde, em cada caso, uma classe está extremamente inserida entre os exemplos da outra classe (Haibo, Yang, Garcia, & Li, 2008). A base de dados que será utilizada neste Artigo é uma base que possui informações sobre todas as pessoas envolvidas em acidentes de carro nas estradas dos EUA durante o ano de 2001. A distribuição das classes desta base de dados é apresentada na Tabela 1

Tab. 1 Distribuição das classes da base de dados

Classes	Números de exemplos
Não Lesão	20007
Possível Lesão	8674
Lesão evidente não-incapacitante	13890
Lesão incapacitante	15072
Lesão Fatal	42116
Gravidade de Lesão Desconhecida	299
Morreu Antes do Acidente	9
Desconhecido	901

Como o atributo de classe não era binário nos dados originais, as instâncias com rótulos de classe *Gravidade de Lesão Desconhecida*, *Morreu Antes do Acidente* e *Desconhecido* foram removidos e os valores da classe binária *lesão* e *não lesão* foram criados. A remoção resultou

em 91085 instâncias, 20007 da classe *não lesão* e 71078 da classe *lesão*. Pode ser observado que a base de dados a ser utilizada possui classes desbalanceadas, o que pode piorar a classificação. Devido a isto, neste Artigo serão utilizados quatro métodos para resolver o problema de classes desbalanceadas, os quais serão descritos nesta seção.

#### A. Undersampling

*Undersampling* aleatória (Kotsiantis & Pintelas, 2003) é um método não heurístico que visa equilibrar a distribuição de classe através da eliminação aleatória de exemplos de classes majoritárias. A lógica atrás disso é tentar equilibrar o conjunto de dados em uma tentativa de superar as idiossincrasias do algoritmo de aprendizado de máquina. A principal desvantagem da *undersampling* aleatória é que esse método pode descartar dados potencialmente úteis que podem ser importantes para o processo de indução. Outro problema com esta abordagem é que o propósito da aprendizagem de máquina é para o classificador estimar a distribuição de probabilidade da população alvo. Como essa distribuição é desconhecida, tentamos estimar a distribuição da população usando uma distribuição de amostra. As estatísticas nos dizem que, enquanto que a amostra seja sorteada aleatoriamente, a distribuição da amostra pode ser usada para estimar a distribuição da população de onde ela foi desenhada. Assim, aprendendo a distribuição da amostra, podemos aprender a aproximar a distribuição alvo. Uma vez que o *undersampling* da classe majoritária seja realizado, a amostra não pode mais ser considerada aleatória.

Dados dois exemplos  $E_i$  e  $E_j$  pertencentes a classes diferentes, e  $d(E_i, E_j)$  é a distância entre  $E_i$  e  $E_j$ ; um par  $(E_i, E_j)$  é chamado de ligação Tomek se não houver um exemplo  $E_1$ , tal que  $d(E_i, E_1) < d(E_i, E_j)$  ou  $d(E_j, E_1) < d(E_i, E_j)$ . Se dois exemplos formam um link Tomek, então um desses exemplos é ruído ou ambos os exemplos são limítrofes. Os links Tomek podem ser usados como um método de *undersampling* ou como um método de limpeza de dados. Como um método de *undersampling*, somente os exemplos pertencentes à classe majoritária são eliminados, e como método de limpeza de dados, os exemplos de ambas as classes são removidos. Kubat e Matwin (Kubat & Matwin, 1997) desenham aleatoriamente um exemplo de classe majoritária e todos os exemplos da classe minoritária e colocam esses exemplos em  $E'$ . Depois, use um 1-NN sobre os exemplos em  $E'$  para classificar os exemplos em  $E$ . Cada exemplo classificado incorretamente de  $E$  é movido para  $E'$ . A ideia atrás dessa implementação de um subconjunto consistente é eliminar os exemplos da classe majoritária que estão distantes

da fronteira de decisão, uma vez que esses tipos de exemplos podem ser considerados menos relevantes para o aprendizado.

### B. Oversampling

O *oversampling* aleatório é um método não heurístico que visa equilibrar a distribuição de classes através da replicação aleatória de exemplos de classes minoritárias. Vários autores (Chawla, Hall, Bowyer, & Kegelmeyer, 2002), (Kubat & Matwin, 1997) concordam que o *oversampling* aleatório pode aumentar a probabilidade de ocorrência de *overfitting*, uma vez que faz cópias exatas dos exemplos de classes minoritárias. Dessa maneira, um classificador simbólico, por exemplo, pode construir regras aparentemente precisas, mas na verdade cobre um exemplo replicado. Além disso, o *oversampling* pode introduzir uma tarefa computacional adicional se o conjunto de dados já estiver razoavelmente grande, mas desequilibrado.

### C. Smote

Em relação à geração de dados sintéticos a técnica de oversampling (Smote) tem mostrado um grande sucesso em várias aplicações (Chawla, Hall, Bowyer, & Kegelmeyer, 2002). O algoritmo Smote cria dados artificiais com base no recurso da semelhança entre os exemplos da classe minoritária existentes. Especificamente, para um subconjunto  $S_{min} \in S$  considere o  $k$  vizinho mais próximo para cada exemplo  $x_i \in S_{min}$ , para algum número inteiro especificado  $k$ ; o  $k$  vizinho mais próximo é definido como elemento de  $S_{min}$  se a distância euclidiana entre ele e  $x_i$  em consideração exibir uma menor magnitude ao longo do espaço  $n$ -dimensional  $X$ . Para criar um exemplo sintético, seleciona-se aleatoriamente um dos seus  $k$  vizinhos mais próximos, então multiplica a diferença entre o correspondente valor por um número aleatório entre  $[0, 1]$ , e finalmente, adiciona este novo valor ao subconjunto  $S_{min}$

$$x_{new} = x_i + (y_i - x_i)\delta, \quad (1)$$

onde  $x_i \in S_{min}$  é um exemplo da classe minoritária em consideração,  $y_i$  é um dos seus  $k$  vizinhos mais próximos de  $x_i : y_i \in S_{min}$ , e  $\delta \in [0, 1]$  é um número aleatório. Portanto, o resultado do exemplo sintético gerado de acordo com a equação seis é um ponto ao longo da reta que une o ponto  $x_i$  em consideração com um dos  $k$  vizinhos mais próximos escolhidos aleatoriamente (He & Garcia, 2009).

### D. Smote + ENN

O método ENN (Edited Nearest Neighbors) foi criado por Wilson em 1972 (García, Villuendas, Medina, Martínez, & Ruiz, 2008) e consiste na eliminação de todos os objetos que são mal

classificados por seus  $k$  - vizinhos mais próximos ( $k$  - NN). Este processo baseia-se basicamente em:

Para cada ponto  $x$  Base de dados

1. Descubrem-se quem são os  $k$  - vizinhos mais próximos de  $x$ .
2. Verifica-se qual a classificação de todos dos  $k$  - vizinhos de  $x$ .
3. Se a classificação de  $x$  for diferente da classificação de todos os seus  $k$  - vizinhos, este ponto é eliminado.

A aplicação do método ENN é feita após a aplicação do método Smote. ENN é utilizado para remover exemplos de ambas as classes. Então qualquer exemplo cuja classificação seja diferente de seus três vizinhos mais próximos é eliminado.

### **Análise de resultados**

Nesta seção são apresentados os testes realizados para as três redes neurais utilizadas neste trabalho. É conhecido que para obter a configuração de rede neural que fornece o melhor desempenho, não existe nenhum método a utilizar. A melhor configuração é obtida testando a rede para diferentes configurações de seus parâmetros. Para o processo de classificação, o conjunto de dados foi dividido em um conjunto de treinamento (70 % do conjunto de dados) e um conjunto de testes (30 %) para as redes PNN e RBF, entretanto para a rede MLP foi dividido em um conjunto de treinamento (70\% do conjunto de dados), um conjunto de validação (20 % do conjunto de dados) e um conjunto de teste (10 % do conjunto de dados) e normalizado entre 0 e 1. A métrica de desempenho usada para comparar os modelos é a porcentagem correta padrões classificados definidos na equação 2.

$$P = 100 \frac{C_c}{N_p}, \quad (2)$$

onde  $P$  é o desempenho dado em porcentagem,  $C_c$  o número de classificações corretas e  $N_p$  o número total de padrões.

Para escolher a configuração a ser utilizada rede MLP foram feitos testes variando o número de neurônios na camada escondida, os quais são apresentados na Figura 5, analisando-se o desempenho da rede no conjunto de validação e teste. Observe que, na Figura 5 a rede MLP apresentou um desempenho similar para os diferentes números de neurônios analisados tanto no conjunto de validação como no conjunto de teste. Na Tabela 2 são apresentados os parâmetros da configuração da rede MLP que forneceu o melhor desempenho.

Tab. 2 Configuração da rede MLP

Número de processadores	4
Função de ativação na camada escondida	tansing
Função de ativação na camada de saída	purelin
Algoritmo de treinamento	trainlm
Número de saídas	2

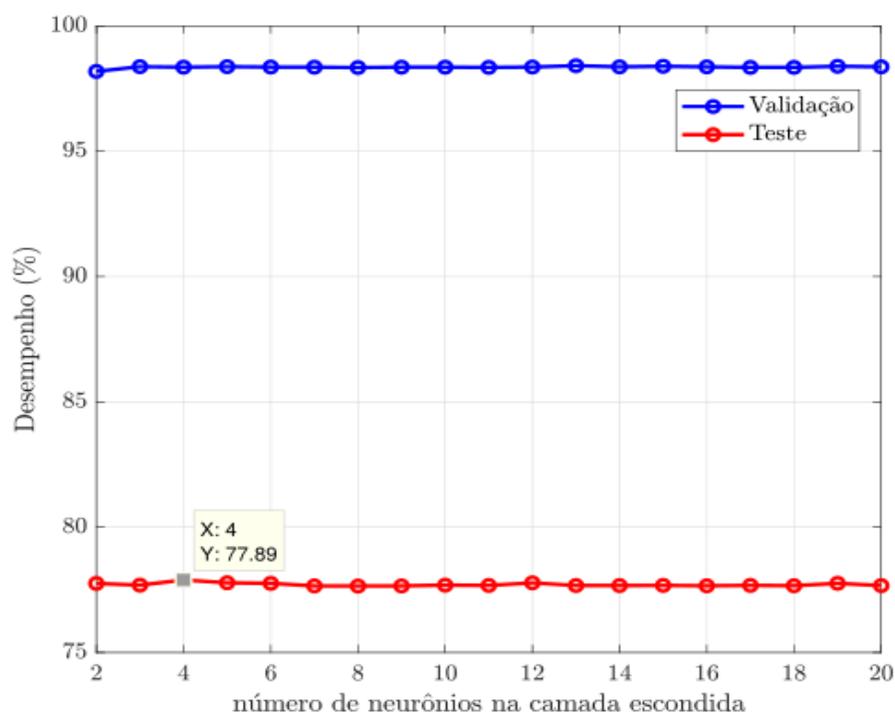


Fig. 5 Teste da rede MLP para diferentes números de neurônios

No caso das redes PNN e RBF que são redes probabilísticas foram feitos vários testes para diferentes valores da constante de espalhamento. Nas Figuras 6 e 7 são apresentados os diferentes valores de constante de espalhamento que foram testados para a rede PNN. Na Figura 6 o primeiro foi feito um teste para valores de constante de espalhamento entre 0,1 e 4,9 observando-se que o melhor desempenho foi obtido para uma constante de espalhamento de 0,1. A partir de este resultado na Figura 7 é apresentado outro teste para valores de constante de espalhamento entre 0,02 e 0,12, neste caso o melhor desempenho foi obtido para uma constante de espalhamento de 0,055, o qual é o valor de constante de espalhamento utilizado nos resultados obtidos para a rede PNN. Um procedimento similar foi feito para a obtenção da constante de espalhamento para a rede RBF, para esta rede a constante de espalhamento é 5,5. Na Tabela 3 são apresentados os resultados obtidos para as três redes testadas. Pode ser

observado na Tabela 3 que a rede PNN forneceu o melhor desempenho na classificação, entretanto a rede MLP apresentou o pior desempenho na classificação.

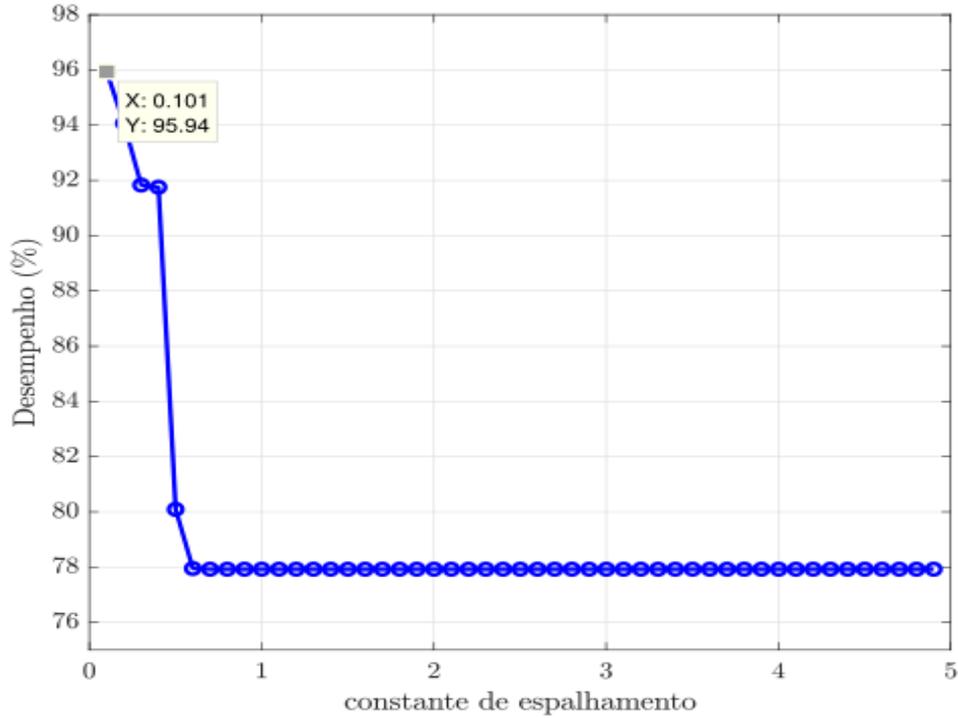


Fig. 6 Teste da rede MLP para diferentes números de neurônios

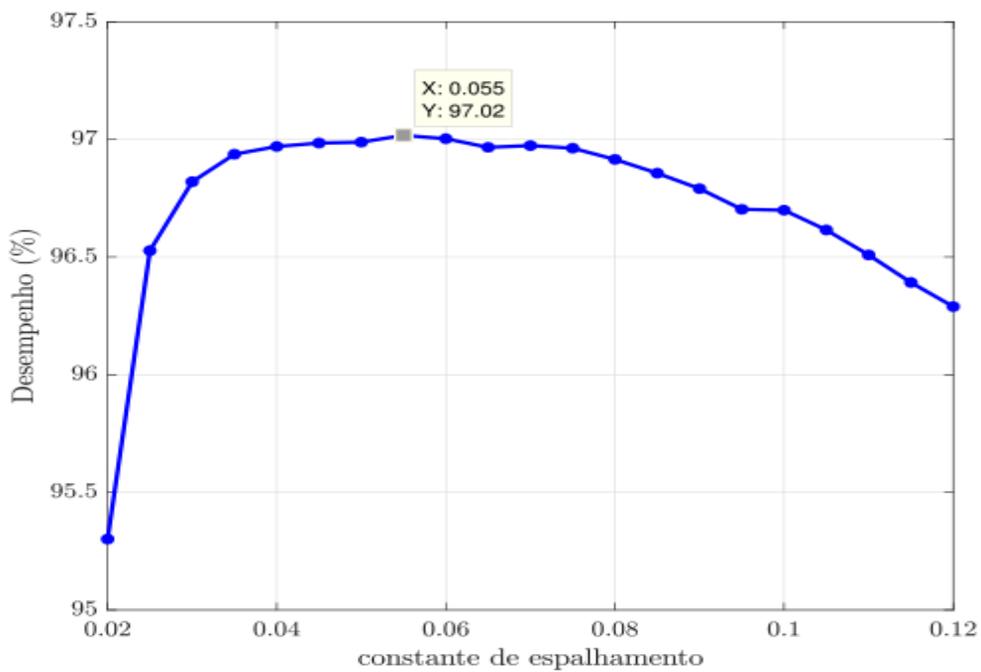


Fig. 7 Estrutura de uma rede RBF

Tab. 3 Desempenho obtido para as redes testadas

	MLP	PNN	RBF
Desempenho (%)	77,8949	97,1308	87,2469

Na Tabela 4 são apresentados os resultados obtidos utilizando-se os métodos de balanceamento de classes apresentados na Seção Descrição da Base de Dados e caracterização do Problema de Classes Desbalanceadas. Neste caso só são apresentados resultados para as redes PNN e RBF que foram às que apresentaram melhores desempenho na Tabela 3. Na Tabela 4 pode ser observado que o método que forneceu o melhor desempenho foi o Smote + ENN, este resultado não é inesperado já que na literatura (Spinelli, 2010), este método é definido como o melhor método dos utilizados neste trabalho. Observou-se também na Tabela 4 que, a rede PNN pioro seu desempenho utilizando-se o método de balanceamento {em undersampling}, entretanto seu desempenho melhorou com os outros métodos utilizados. Ainda na Tabela 4 é observado que, a rede RBF piora seu desempenho para todo os métodos de balanceamento utilizados.

Tab. 4 Desempenho obtido para as redes utilizando-se balanceamento de classes

Desempenho		
Métodos de balanceamento	PNN	RBF
Undersampling	96,2806	80,4127
Oversampling	98,0547	83,1925
Smote	97,9630	83,8594
Smote + ENN	98,8346	82,3699

## Conclusões

1. Foram descritas as redes MLP, PNN e RBF baseando-se na sua arquitetura e configuração de parâmetros. Foi apresentada uma breve descrição dos métodos balanceamento de classes, os quais foram utilizados para resolver o problema de classes desbalanceadas que tinha a base de dados utilizada. Foram testadas as três redes consideradas neste trabalho primeiro sem a utilização de métodos de balanceamento, neste teste a rede PNN forneceu o melhor desempenho na classificação. Finalmente foi feito outro teste utilizando métodos de balanceamento para as redes PNN e RBF. Neste caso, observado que, a rede PNN pioro seu desempenho utilizando-se método de balanceamento *undersampling*, entretanto seu desempenho

melhorou com os outros métodos, obtendo-se o melhor desempenho com o método Smote + ENN.

2. Conclua-se que o trabalho feito mostra um modelo matemático teórico para a estimação de um sinal de entrada utilizando o filtro de Wiener, assim como os passos para obter o filtro ótimo partindo da função densidade espectral de potência. Com o uso do programa de simulação Matlab foi mostrado como o sinal de entrada pode ser obtida praticamente. Ademais, este trabalho servirá como ferramenta de estudos para estudantes de sistemas de comunicações já que é um complemento entre o marco teórico e prático para detecção de sinal.

### **Referências bibliográficas**

- Bonifácio, F. N. (2010). Comparação entre as Redes Neurais Artificiais MLP, RBF e LVQ na Classificação de Dados. Paraná: Universidade Estadual do Oeste do Paraná.
- Carvalho, C. B. (2000). Redes Neurais Artificiais: *Teoria e Aplicações*. Rio de Janeiro.
- Chawla, N., Hall, L., Bowyer, K., & Kegelmeyer, W. (2002). SMOTE: Synthetic. *Journal of Artificial Intelligence Research*, 16, 321-357.
- García, M., Villuendas, Y., Medina, M., Martínez, J., & Ruiz, J. (2008). Selección y construcción de objetos para el mejoramiento de un clasificador supervisado: un análisis crítico. Havana: Centav.
- Haibo, H., Yang, B., Garcia, E., & Li, S. (2008). DASYN: Adaptive Synthetic Sampling Approach for Imbalanced. *International Joint Conference on Neural Networks (IJCNN 2008)*, 1322-1329.
- He, H., & Garcia, E. (2009). Learning from Imbalanced Data. *IEEE*.
- JL Murray, C., D Lopez, A., Mathers, C., & Stein, C. (2001). The Global Burden of Disease 2000. World Health Organization. Fonte: <http://www.who.int/healthinfo/paper36.pdf>
- Kotsiantis, S., & Pintelas, P. (2003). Mixture of Expert Agents for Handling Imbalanced Data Sets. *Annals of Mathematics, Computing and Teleinformatics*, 1, 46-55.
- Kubat, M., & Matwin, S. (1997). Addressing the curse of imbalanced training sets: One sided selection. *In Proceedings of the Fourteenth International Conference on Machine Learning*, 179-186.
- Peden, M. (2004). World report on road traffic injury prevention. World Health Organization. Fonte: <http://www.who.int/healthinfo/paper36.pdf>

- Spinelli, A. (2010). Um estudo comparativo de métodos para balanceamento do conjunto de treinamento em aprendizado de redes neurais artificiais.
- Velasco, M. (2018). Apresentações das aulas de Redes Neurais.
- World Health , O. (2008). World health statistics 2008. *World Health Organization*. Geneve.  
Fonte: [http://www.who.int/gho/publications/world\\_health\\_statistics/EN\\_WHS08\\_Full.pdf](http://www.who.int/gho/publications/world_health_statistics/EN_WHS08_Full.pdf)
- World Health, O. (2008). The Global Burden of Disease: 2004 update. *Organization, World Health*. Geneve. Fonte:  
[http://www.who.int/healthinfo/global\\_burden\\_disease/GBD\\_report\\_2004update\\_full.pdf?ua=1](http://www.who.int/healthinfo/global_burden_disease/GBD_report_2004update_full.pdf?ua=1)