

# ESTUDO DO DESEMPENHO DE REDES NEURAIAS ARTIFICIAIS NA CONSTRUÇÃO DE SÉRIES LONGAS DE REFLECTÂNCIA DE SENSORIAMENTO REMOTO

Fábio Dall Cortivo<sup>1,a</sup>, Milton Kampel<sup>1,b</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais (INPE) Av. dos Astronautas, 1.758 – Jardim da Granja, São José dos Campos – SP, 12227-010; {<sup>a</sup>fabio.cortivo;<sup>b</sup>milton.kampel}@inpe.br

## RESUMO

Esse trabalho visa avaliar o desempenho de redes neurais artificiais quando aplicadas com a finalidade de se obter séries temporais longas para reflectância de sensoriamento remoto (RRS). Foi utilizado o período de sobreposição das imagens (2002-2006) SeaWiFS e Modis/Aqua, na região de plataforma da Bacia de Santos, para treinar uma rede neural do tipo Perceptron de Múltiplas Camadas, a fim de converter as RRS nas bandas visível do sensor SeaWiFS em RRS Modis/Aqua nas bandas 443, 488 e 547, que são as bandas Modis/Aqua utilizadas no algoritmo OC3M para estimativa de clorofila. Os resultados apresentados avaliam o desempenho da rede na conversão das reflectâncias SeaWiFS em reflectâncias Modis/Aqua para o período de sobreposição. Para esta validação foi comparado a RRS Modis/Aqua com a RRS dada pela rede. Os resultados mostram  $R^2 \geq 0,80$  e correlação entre as séries (para cada banda) superior a 0,9.

**Palavras-chave** – inteligência artificial, redes neurais, séries longas, reflectância de sensoriamento remoto, cor do oceano.

## ABSTRACT

*This work aims to evaluate the performance of artificial neural networks when applied in order to obtain long time series for remote sensing reflectance (RRS). The overlapping period of the images (2002-2006) SeaWiFS and Modis/Aqua, in the shelf region of the Santos Basin, was used to train a neural network of the Multi-Layer Perceptron type, in order to convert the RRS in visible bands of the SeaWiFS sensor into RRS Modis/Aqua in bands 443, 488 and 547. These Modis/Aqua bands are used in the OC3M algorithm for chlorophyll estimation. The presented results evaluate the performance of the network in the conversion of SeaWiFS reflectances into Modis/Aqua reflectances for the overlapping period. For this validation, the RRS Modis/Aqua was compared with the RRS given by the network. The results show  $R^2 \geq 0,80$  and a correlation between the series (for each band) greater than 0,9.*

**Key words** – artificial intelligence, neural networks, long data series, remote sensing reflectance, ocean color.

## 1. INTRODUÇÃO

Os serviços ecossistêmicos marinhos, como o suporte à pesca e sequestro de carbono contribuem para o bem-estar humano. O fitoplâncton é a base da cadeia trófica marinha e

fornece serviços categorizados como reguladores, com papel importante na fixação do CO<sub>2</sub> atmosférico e sua sedimentação em águas profundas; e de produção através do processo de fotossíntese e ciclagem de nutrientes suportando bens e serviços utilizados por seres humanos (incluindo 50% do oxigênio que respiramos) [1, 2].

Os organismos fitoplanctônicos marinhos são, no entanto, os mais suscetíveis às mudanças ambientais devido ao seu curto ciclo de vida e por atuarem como uma interface entre o ambiente e a biota marinha (transformando elementos simples como água, CO<sub>2</sub> e nutrientes em matéria orgânica com energia solar). Mudanças climáticas poderão induzir a formação de uma camada de mistura mais rasa e estável limitando o crescimento de células fitoplanctônicas maiores que tem papel mais significativo no sequestro do carbono [3]. Mudanças físico-químicas no ambiente podem também afetar o tempo (*timing*, início e fim) e intensidade das florações (*blooms*) fitoplanctônicas com consequências na alimentação de larvas de peixes e estoques pesqueiros [4]. Portanto, o monitoramento do fitoplâncton marinho, indexado pela concentração de clorofila-*a*, é essencial para entender o funcionamento da base dos ecossistemas e seus serviços, bem como, os impactos das mudanças provocadas por alterações antropogênicas e climáticas.

O sensoriamento remoto orbital é uma ferramenta importante de monitoramento possibilitando a aquisição de dados sistemáticos, com ampla cobertura espacial e alta frequência de revisita, e com baixo custo para os usuários. A proliferação de missões da cor do oceano representa uma excelente oportunidade para o desenvolvimento de diversas aplicações oceanográficas e ecológicas. Entretanto, diferenças nos períodos e durações das diversas missões resultam em registros de dados relativamente curtos que podem não ser adequados, individualmente, para a análise de mudanças de longo período. Há, portanto, necessidade de se construir séries temporais mais longas, que podem ser obtidas pela combinação dos conjuntos de dados das diferentes missões.

As diferentes especificações e/ou calibração entre diferentes sensores de diferentes missões, faz com que se tenha diferentes valores (numéricos), para um mesmo pixel e/ou região, para uma determinada variável de interesse. Dessa forma, é necessário aplicar algum método matemático e/ou estatístico a fim de “converter” uma medida em outra, a partir de um sensor tomado como referência, de modo que se tenha uma função que “aproxime/converte” essas duas medidas.

Visto que os algoritmos utilizados para estimar a concentração de clorofila-*a* usam a razão entre determinadas bandas da reflectância de sensoriamento remoto (RRS), como

variável de entrada, se torna interessante combinar diferentes séries temporais de RRS de diferentes sensores para se obter uma única série longa. O objetivo desse trabalho é avaliar o desempenho de redes neurais artificiais na tentativa de combinar a série de RRS, na faixa do visível, do sensor SeaWiFS com a série de RRS do sensor Modis/Aqua, nos comprimentos de onda 443, 488 e 547 nanômetros, as quais são utilizadas no algoritmo para estimativa de clorofila-a OC3M [5].

## 2. MATERIAL E MÉTODOS

### 2.1. Região de estudo e seleção dos dados

A área de estudo corresponde a região de plataforma, delimitada pela isóbata de 200m, da Baía de Santos (Figura 1). Esse trabalho adota apenas a região de plataforma devido às grandes diferenças das características ambientais e espectrais entre plataforma e talude. As imagens SeaWiFS e Modis/Aqua usadas nesse trabalho foram adquiridas do site *OceanColor* [6] para o período de 2002 até 2006. Embora o sensor SeaWiFS tenha operado até 2010, para a região de estudo só há imagens disponíveis/válidas até o ano de 2006. Posteriormente, foram processadas utilizando o *software* Seadas com configuração de correção atmosférica padrão, para todo o período de sobreposição de imagens, com resolução espacial de 1km.

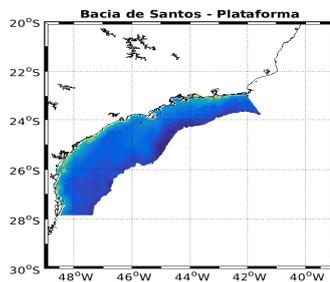


Figura 1: Região de plataforma da Baía de Santos.

O passo seguinte foi determinar, a partir do período de sobreposição de imagens (04/07/2002 até 21/12/2006), os dias nos quais há imagens para ambos sensores. Posteriormente, foi feita a intersecção dos pixels das imagens de modo a garantir que um pixel<sub>xy</sub>, válido em uma imagem Modis, também fosse válido na mesma posição *xy* em uma imagem SeaWiFS. Após essas duas operações foram obtidas 771 imagens válidas para a região de estudo.

Dado o grande número de imagens válidas, a seleção de imagens para formar o conjunto de treinamento da rede, foi feito por amostra estatística de modo que, o  $N_a$  amostral foi definido por

$$N_a = \frac{z^2 p(1-p)}{e^2} \left/ \left( 1 + \frac{z^2 p(1-p)}{e^2 N} \right) \right., \quad (1)$$

em que  $z$  é o escore associado ao nível de confiança,  $e$  é a margem de erro,  $p$  é uma constante (que representa a probabilidade da amostra estar representando a verdade) e  $N$  é o tamanho da população. Foi adotado  $z = 2,58$  e  $e = 5\%$ , o que significa que a margem de erro é de 5% com um nível

de confiança de 99%, ainda  $p = 0,5$  e  $N = 771$ . Com estas condições o  $N_a$  total foi de 358 imagens, as quais foram escolhidas aleatoriamente sobre a população total de imagens, e que foram usadas para montar o conjunto de treinamento.

Em virtude do número total de pixels válidos (para cada comprimento de onda de interesse) nestas 358 imagens ser muito elevado com um total de 5.666.242 pixels, repetiu-se o processo de amostragem realizado anteriormente, utilizando os mesmos valores para as variáveis  $z$ ,  $e$  e  $p$ , no entanto, trocando o  $N = 771$  pelo número total de pixels válidos em cada imagem. Dessa forma, foi selecionado uma amostra dos pixels válidos em cada uma das imagens previamente selecionadas. Assim, o total de pixels selecionados para formar o conjunto de treinamento, para cada comprimento de onda (banda) de interesse foi de 185.573 pixels.

### 2.2. Modelo e treinamento da rede

O modelo adotado nesse trabalho consiste em treinar uma rede neural artificial, do tipo perceptron de múltiplas camadas, para converter medidas de reflectância SeaWiFS em medidas de reflectância Modis/Aqua. Nesse sentido, o conjunto de padrões de entrada para o treinamento da rede é formado pelas reflectâncias do sensor SeaWiFS nas bandas  $Rrs_{412}$ ,  $Rrs_{443}$ ,  $Rrs_{490}$ ,  $Rrs_{510}$ ,  $Rrs_{555}$  e  $Rrs_{670}$ . O conjunto de padrões de saída é formado pelas reflectâncias nas bandas  $Rrs_{443}$ ,  $Rrs_{488}$  e  $Rrs_{547}$  do sensor Modis/Aqua. Para realizar esse mapeamento, a rede neural será treinada utilizando o período de sobreposição de imagens dos dois sensores. Desse modo, será possível fazer o mapeamento entre as RRS do sensor SeaWiFS e as RRS do sensor Modis/Aqua que são utilizadas no algoritmo OC3M [5].

O conjunto de padrões de entrada a ser usado no treinamento foi formado pelas reflectâncias disponíveis para o sensor SeaWiFS e, para o conjunto de padrões de saída foram adotadas apenas as reflectâncias de interesse que são utilizadas no algoritmo OC3M [5] para cálculo da concentração de clorofila. Dessa forma, a configuração da rede apresenta seis neurônios na camada de entrada e três neurônios na camada de saída. Note que cada neurônio representa uma banda de RRS. O número de camadas ocultas e o número de neurônios em cada uma dessas camadas são definidas de maneira *ad-hoc* durante o processo de treinamento [7].

Como foi utilizado o método de treinamento de validação cruzada [7, 8], o total de padrões de entrada foi dividido em duas partes. A primeira, chamada de conjunto de treinamento, foi composta por 139.180 padrões (75% do total) e os 46.393 padrões restantes (25%) foram utilizados para compor o conjunto de teste, o qual é utilizado durante o processo de treinamento. Nesta metodologia o treinamento é interrompido quando o erro mínimo pré-definido é atingido, ou quando o desempenho da rede sobre o conjunto de teste começa a se degradar, ou ainda, quando o número de épocas previstas para o treinamento é atingido [7, 8]. Ainda, segundo [7], estratégia de validação cruzada evita o efeito *overfitting*, o qual torna a rede especialista nos padrões de treinamento mas apresenta respostas degradadas quando são apresentados à ela dados que não estavam presentes durante o processo de treinamento. Os demais pixels das 358 imagens

compunham o conjunto de validação o qual foi utilizado para avaliar o desempenho da rede treinada, cujos resultados serão apresentados na próxima seção.

A fim de se eliminar dados espúrios dos conjuntos de dados foi considerado que nenhum valor de RRS pode ser menor do que zero, nenhum valor de RRS superior a  $0,02sr^{-1}$  para comprimentos de onda até 555 nanômetros e nenhum valor de RRS superior a  $0,015sr^{-1}$  para comprimento de onda de 670nm [9].

A fundamentação matemática para o treinamento da rede foi baseada no método Quasi-Newton [10], o qual consiste na minimização de um funcional de diferenças quadráticas dado por:

$$\mathcal{J}(\mathbb{E}, \mathbb{W}, \mathbb{B}, \Gamma) = \min \frac{1}{2} \sum_{p=1}^{N_p} \sum_{k=1}^{N_s} \|d_{kp}(\mathbb{E}) - y_{kp}(\mathbb{E}, \mathbb{W}, \mathbb{B}, \Gamma)\|_2^2, \quad (2)$$

em que,  $\mathbb{E}$  é uma matriz que contém os padrões de entrada,  $\mathbb{W}$  é uma matriz que contém todos os pesos sinápticos,  $\mathbb{B}$  é uma matriz que contém todos os níveis de viés, e  $\Gamma$  é uma matriz que contém todos os parâmetros das funções de ativação,  $N_s$  representa o número total de neurônios na camada de saída,  $N_p$  representa o número total de padrões de treinamento,  $d_{kp}(\cdot)$  e  $y_{kp}(\cdot, \mathbb{W}, \mathbb{B}, \Gamma)$  representam, respectivamente, cada entrada das matrizes que contém os padrões de saída para o treinamento e as saídas calculadas pela rede. Mais detalhes sobre a metodologia de treinamento adotada podem ser encontrados em [11].

Por fim, é mostrada a topologia da rede utilizada, a qual consiste de uma camada de entrada com seis neurônios, uma camada oculta com 40 neurônios e uma camada de saída com três neurônios (Figura 2).

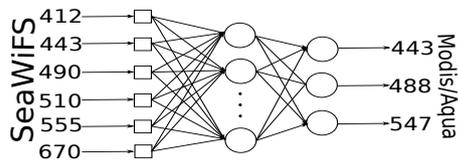


Figura 2: Topologia da rede utilizada.

Para as funções de ativação de cada neurônio da camada oculta foi utilizada a função logaritmo natural dada por:

$$\phi(\gamma, v) = \begin{cases} \ln(1 + \gamma v) & \text{se } v \geq 0 \\ -\ln(1 - \gamma v) & \text{se } v < 0 \end{cases}, \quad (3)$$

e para os neurônios da camada de saída foi adotada a função linear  $\phi(\gamma, v) = \gamma v$ , em que  $\gamma$  é a inclinação e  $v$  é o campo local induzido [7].

### 3. RESULTADOS E DISCUSSÃO

Os resultados apresentados neste trabalho se concentram em avaliar o desempenho da rede, sobre os dados do período em que há sobreposição de imagens (2002-2006) para os dois sensores considerados. Os gráficos e as estatísticas que são apresentados se referem ao conjunto de validação, ou seja, todos aqueles padrões que não foram utilizados nem para treinar nem para testar a rede durante o processo de aprendizagem (procedimento de validação cruzada). Ainda, foram incluídos no conjunto de validação os pixels válidos

daquelas imagens que não foram selecionadas para formar o conjunto de treinamento. Portanto, o total de padrões de entrada (RRS SeaWiFS) presentes no conjunto de validação, já levando em conta a mesma filtragem pelos limiares adotados no conjunto de treinamento, é de 11.646.785 para cada comprimento de onda (banda) de interesse.

O processamento desse conjunto de padrões pela rede neural produziu um conjunto de saída de RRS “aproximadas” Modis/Aqua, que será definido como RRS Modis/RNA. Esse conjunto será comparado com as RRS “verdadeiras” Modis/Aqua, a fim de avaliar o desempenho da rede. Sobre as RRS Modis/RNA (saída da rede) também foram aplicados os limiares a fim de eliminar os dados espúrios. Após essa filtragem o conjunto total sofreu uma redução de 3.002 padrões, resultando em um total de 11.643.783 padrões válidos para cada uma das RRS ( $Rrs_{443}$ ,  $Rrs_{488}$  e  $Rrs_{547}$ ).

A avaliação do desempenho da rede foi feita para cada um dos comprimentos de onda. Para cada um deles foi feito o ajuste de mínimos quadrados considerando a reta  $f(x) = ax + b$ . Além disso, foram calculadas as medidas estatísticas de correlação,  $R^2$  e o erro quadrático médio (RMSE).

Os gráficos de dispersão das RRS Modis/Aqua versus RRS Modis/RNA para os comprimentos de onda 443, 488 e 547 nm (Figuras 3, 4 e 5, respectivamente). As medidas estatísticas obtidas (Tabela 1) quando comparadas as RRS Modis/Aqua e Modis/RNA indicam que os resultados obtidos são robustos.

O fato de se estar considerando águas costeiras é de se esperar que o sinal da radiação eletromagnética seja menos intenso na faixa do azul, e que aumente gradativamente a medida que a frequência diminui [12, 13]. Note que, boa parte dos valores de RRS estão concentrados próximos de zero (Figura 3). Por outro lado (Figura 4) o sinal espectral tende a ter valores com ordem de grandeza maior e o mesmo pode ser observado para a reflectância em 547 nm (Figura 5).

Uma vez que o sinal pode ser relativamente menos intenso para a  $Rrs_{443}$ , a relação sinal/ruído dificulta a o aprendizado da rede. Conseqüentemente, a conversão das reflectâncias SeaWiFS para Modis/RNA também ficam prejudicadas. De qualquer forma, foi possível obter uma correlação superior a 90% entre as séries Modis/Aqua e Modis/RNA com  $R^2 > 0,8$ .

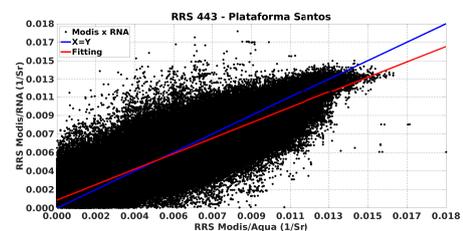
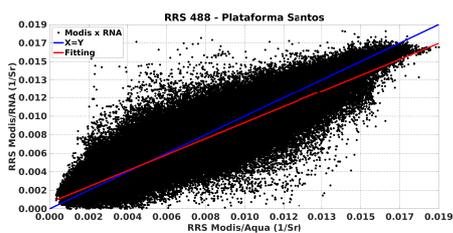


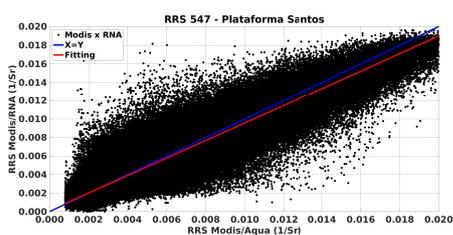
Figura 3: Gráfico de dispersão das reflectâncias de sensoriamento remoto versus reflectâncias obtidas pela rede neural para comprimento de onda em 443 nanômetros.

Para a  $Rrs_{488}$  (Figura 4) o sinal apresenta maior grandeza e uma provável relação sinal ruído menor, quando comparado à  $Rrs_{443}$ . Isso pode ter facilitado o aprendizado da rede. Nesse caso foi possível obter uma correlação superior a 93% entre as séries e  $R^2 \approx 0,99$  (Figura 4 e Tabela 1).



**Figura 4:** Gráfico de dispersão das reflectâncias de sensoriamento remoto versus reflectâncias obtidas pela rede neural para comprimento de onda em 488 nanômetros.

Para a  $Rrs_{547}$ , (Figura 5) foi obtido um ótimo resultado com correlação superior a 97% entre as séries e  $R^2 = 0,95$ .



**Figura 5:** Gráfico de dispersão das reflectâncias de sensoriamento remoto versus reflectâncias obtidas pela rede neural para comprimento de onda em 547 nanômetros.

	Corr	$R^2$	RMSE	$a$	$b$
$Rrs_{443}$	90,53	0,82	$7,2 \cdot 10^{-4}$	0,834	$8,1 \cdot 10^{-4}$
$Rrs_{488}$	93,60	0,88	$5,5 \cdot 10^{-4}$	0,865	$6,4 \cdot 10^{-4}$
$Rrs_{547}$	97,23	0,95	$4,4 \cdot 10^{-4}$	0,943	$1,4 \cdot 10^{-4}$

**Tabela 1:** Medidas estatísticas obtidas quando comparada as séries Modis/Aqua e as séries Modis/RNA para cada uma das bandas.

#### 4. CONCLUSÕES

A utilização de redes neurais para converter as reflectâncias do sensor SeaWiFS em reflectâncias “aproximadas” Modis/Aqua se mostrou bastante robusta. Isso se deve ao fato de que em nenhuma das bandas foram obtidas correlações inferiores a 0,9 sobre o conjunto de validação. Vale lembrar que os dados do conjunto de validação não estiveram presentes durante o treinamento da rede, *i.e.*, são valores completamente “desconhecidos” para a rede neural. Isso comprova a excelente capacidade de generalização do aprendizado por parte da rede neural.

Os resultados obtidos são robustos e, dessa forma, é possível juntar toda a série de dados SeaWiFS (1997-2006) com a série de dados Modis/Aqua (2002-2022) a fim de se obter séries de reflectância de sensoriamento remoto com aproximadamente 25 anos e, então, derivar os produtos (como clorofila-*a*) que consideram a reflectância como variável de entrada.

#### 5. AGRADECIMENTOS

Ao Programa de Capacitação Institucional (PCI) do INPE pela bolsa concedida durante o período de 02/2017 até

09/2021. Processos: 300123/2017-5, 300314/2019-1, 300203/2020-9, 301042/2020-9, 300242/2021-2, 301576/2021-1 e 302040/2021-8 e a FUSP pela bolsa de pós-doutorado (N. 899, 2017/00686-0) a partir de 10/2021. Agradecer a NASA Goddard Space Flight Center, Ocean Ecology Laboratory, Ocean Biology Processing Group pelo acesso aos bancos de dados de imagens dos sensores SeaWiFS e Modis/Aqua.

#### 6. REFERÊNCIAS

- [1] Robert de Groot, Matthew A Wilson, and Roelof M.J Boumans. A typology for the classification, description and valuation of ecosystem functions, goods and services. *Ecological Economics*, 41(3):393 – 408, 2002.
- [2] Christopher B. Field, Michael J. Behrenfeld, James T. Randerson, and Paul Falkowski. **Primary Production of the Biosphere: Integrating Terrestrial and Oceanic Components.** *Science*, 281(5374):237–240, 1998.
- [3] Michael Behrenfeld, Robert O’Malley, David Siegel, Charles McClain, Jorge Sarmiento, Gene Feldman, Allen Milligan, Paul Falkowski, Ricardo Letelier, and Emmanuel Boss. **Climate-driven trends in contemporary ocean productivity.** *Nature*, 444:752–5, 01 2007.
- [4] Trevor Platt and Kenneth Frank. Marine ecology: Spring algal bloom and larval fish survival. *Nature*, 423:398–9, 06 2003.
- [5] J. E. O’Reilly, S. Maritorena, D. A. Siegel, M. C. O’Brien, D. Toole, B. G. Mitchell, M. Kahru, F. P. Chavez, P. Strutton, G. F. Cota, S. B. Hooker, C. R. McClain, K. L. Carder, F. Muller-Karger, L. Harding, A. Magnuson, D. Phinney, G. F. Moore, J. Aiken, K. R. Arrigo, R. Letelier, and M. Culver. Nasa technical memorandum 2000-206892. Technical report, Maryland, 2000.
- [6] Project. Ocean, Color. Ocean color project, 2013.
- [7] S. Haykin. *Neural networks*. Prentice Hall, 2 edition, jul 1999.
- [8] L. Fausett. *Fundamentals of neural networks*. Prentice Hall International, New Jersey, 1994.
- [9] EarthData. Seabass, [https://seabass.gsfc.nasa.gov/wiki/hyperspectral\\_rrs\\_examples](https://seabass.gsfc.nasa.gov/wiki/hyperspectral_rrs_examples), 2022.
- [10] J. E. Dennis and J. J. Moré. Quasi-Newton methods, motivation and theory. *Society for Industrial and Applied Mathematics Review*, 19(1):46–89, 1977.
- [11] F. D. Cortivo. Estimativa do perfil da concentração de clorofila em águas naturais com o uso de redes neurais artificiais. Doutorado em computação aplicada, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.
- [12] C. D. Mobley. *Light and water*. Academic Press, California, 1994.
- [13] André Morel and Stephane Maritorena. Bio-optical properties of oceanic waters: A reappraisal. *Journal of Geophysical Research*, 106:7163–7180, 2001.