

Uso de Redes Neurais na Desconvolução Preditiva de Traços Sísmicos

Maiane Junqueira Teixeira Neto e Rafael Ferrari

Resumo—A desconvolução de sismogramas que apresentam assinatura da fonte de fase mista é um problema desafiador que não pode ser satisfatoriamente resolvido através de preditores lineares. Assim, este trabalho tem por objetivo investigar o uso de Filtros de Erro de Predição Progressivo a Passo Unitário não lineares, especificamente, redes neurais nesse tipo de cenário. A proposta se baseia no sucesso que essas estruturas apresentam na equalização de canais de comunicação de fase mista e os resultados preliminares obtidos são bastante promissores, motivando a continuação das investigações da técnica em cenários mais complexos.

Palavras-Chave—Desconvolução preditiva, redes neurais, fase mista.

Abstract—Deconvolution of mixed phase sismograms is a challenging problem which is not successfully solved through linear predictors. Thus, this paper investigates the use of nonlinear Forward Prediction Error Filters, specifically neural networks on mixed phase scenarios. This approach is based on the effectiveness of these structures in mixed phase equalization problems and the preliminary results are promising, which encourage further research in more complex scenarios.

Keywords—Predictive deconvolution, neural network, mixed-phase.

I. INTRODUÇÃO

Um sinal pode ser definido como uma função que contém informação [1] e, neste sentido, o sismograma pode ser modelado como tal, em que é possível recuperar informações de interesse à sísmica de reflexão. Por sua vez, a sísmica de reflexão é uma técnica que permite produzir uma imagem da subsuperfície [2]. Nela, são realizados experimentos sísmicos ao longo da superfície que consistem da produção de pulsos sísmicos que se propagam pelas diferentes camadas da terra.

Um experimento sísmico pode ser interpretado como uma tentativa de se estimar a resposta ao impulso da subsuperfície, denominada função refletividade [2]. Trata-se de uma série temporal composta por impulsos cujas magnitudes e instantes de ocorrência estão associados aos coeficientes de reflexão das interfaces das camadas geológicas da subsuperfície. Devido à relação entre as interfaces e os impulsos presentes na função refletividade, sua análise permite a obtenção de informações sobre a disposição das estruturas geológicas presentes no subsolo. Desse modo, um sismograma $x(n)$ pode ser modelado como

$$x(n) = h(n) * r(n) + \eta(n), \quad (1)$$

Maiane Junqueira Teixeira Neto, Faculdade de Engenharia Elétrica e Engenharia da Computação, Universidade Estadual de Campinas, Campinas, e-mail: m190653@dac.unicamp.br; Rafael Ferrari, Faculdade de Engenharia Elétrica e Engenharia da Computação, Universidade Estadual de Campinas, Campinas, e-mail: rferrari@dca.fee.unicamp.br. Este trabalho foi financiado pelo CNPq (163388/2018-0). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

em que $h(n)$ é a assinatura da fonte, $r(n)$ é a função refletividade e $\eta(n)$ é um ruído aditivo e $*$ é o operador de convolução.

A presença da assinatura da fonte no sismograma pode fazer com que interfaces próximas se sobreponham, impedindo a identificação de eventos próximos [2]. Definem-se como camadas geológicas próximas aquelas em que o intervalo de tempo entre os eventos é menor que a duração da *wavelet*. Tal definição nos é pertinente, pois na busca pela melhor representação da subsuperfície da terra, a proximidade entre as interfaces geológicas faz com que ocorra a sobreposição de eventos sísmicos, dificultando a identificação de eventos nesses locais.

Um método de recuperação da refletividade amplamente utilizado chama-se desconvolução que corresponde ao processo analítico que desfaz uma operação de filtragem anterior, denominada convolução. No âmbito da sísmica de reflexão, um método muito comum que geralmente é empregado é a desconvolução preditiva, que se baseia em Filtros de Erro de Predição Progressivo a Passo Unitário (FEPPPU) lineares [2]. Entretanto, essa técnica apresenta limitações de desempenho quando a assinatura da fonte é de fase mista [2]. Neste trabalho, propomos o uso de filtros não lineares, especificamente redes neurais artificiais, como preditores para lidar com assinaturas de fase mista. A proposta se motiva no sucesso dessas estruturas na área de equalização não supervisionada demonstrado em trabalhos anteriores, um problema que apresenta semelhanças com a desconvolução sísmica [3], [4], [5].

II. PREDIÇÃO

Predição pode ser interpretada como um caso particular de filtragem que busca estimar valores futuros de uma série temporal utilizando os valores passados do sinal analisado. Em outras palavras, seja $x(n)$ uma amostra de uma série temporal qualquer, temos que a Predição Linear Progressiva a Passo Unitário de $x(n)$ é dada por

$$\hat{x}(n) = F[\mathbf{x}(n-1)], \quad (2)$$

em que $F[\cdot]$ é a função que expressa o mapeamento entre as entradas e a saída do preditor e $\mathbf{x}(n-1) = [x(n-1) \ x(n-2) \ \dots \ x(n-M)]^T$.

O erro de predição é definido como a diferença entre $x(n)$ e a estimativa produzida pelo preditor

$$e(n) = x(n) - F[\mathbf{x}(n-1)] \quad (3)$$

Em particular, quando a saída do preditor é uma combinação linear das amostras passadas da série, ou seja, o preditor corresponde a um filtro FIR (do inglês *Finite Impulse Response*),

temos

$$\hat{x}(n) = \sum_{k=1}^M w_k x(n-k) = \mathbf{w}^T \mathbf{x}(n-1), \quad (4)$$

em que $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_M]^T$ são os coeficientes do preditor.

Dessa forma, o erro pode ser reescrito como

$$\begin{aligned} e(n) &= x(n) - \mathbf{w}^T \mathbf{x}(n-1) \\ &= \mathbf{a}^T \mathbf{x}(n), \end{aligned}$$

em que $\mathbf{x}(n) = [x(n) \ \mathbf{x}^T(n-1)]^T$ e $\mathbf{a} = [1 \ -\mathbf{w}^T]^T$ é o vetor que contém os coeficientes do FEPPPU. No caso linear, o projeto do preditor envolve a determinação do vetor de coeficientes \mathbf{w} que, classicamente, é realizada através da minimização do Erro Quadrático Médio (EQM) de predição. Desse modo, os coeficientes ótimos do filtro são obtidos através da equação de Wiener-Hopf [6], [1]

$$\mathbf{w}_o = \mathbf{R}^{-1} \mathbf{p}, \quad (5)$$

em que $\mathbf{R} = E\{\mathbf{x}(n-1)\mathbf{x}(n-1)^T\}$ é a matriz de autocorrelação do sinal de entrada do preditor e $\mathbf{p} = E\{x(n-1)\mathbf{x}(n-1)^T\}$ é o vetor de correlação cruzada entre $\mathbf{x}(n-1)$ e o sinal de referência $x(n)$.

O FEPPPU Linear ótimo, $\mathbf{a}_o = [1 \ -\mathbf{w}_o^T]^T$, apresenta duas propriedades interessantes [6], [1], [7]:

- 1) É um filtro branqueador, ou seja, à medida que sua ordem aumenta, o erro de predição tende a ser um processo branco;
- 2) O filtro sempre é de fase mínima, o que significa que todos os seus zeros estão dentro do círculo de raio unitário.

Essas propriedades mostram-se úteis na desconvolução de traços sísmicos como veremos na próxima seção.

III. DESCONVOLUÇÃO PREDITIVA

O problema de desconvolução sísmica consiste em obtermos um filtro que aproxime a inversa de $h(n)$ de modo a recuperar o sinal $r(n)$ a partir exclusivamente de $x(n)$, ou seja, trata-se de um problema de filtragem inerentemente não supervisionado. O FEPPPU é uma estrutura que pode ser usada para realizar a desconvolução não supervisionada. Entretanto, para isso, é necessário que algumas hipóteses sejam respeitadas: $r(n)$ deve ser um processo branco, composto por amostras independentes e igualmente distribuídas (i.i.d.), e o sistema que introduz as distorções, $h(n)$, precisa ser linear e invariante com o tempo [7].

Robinson foi pioneiro ao sugerir o uso de um FEPPPU linear na desconvolução não supervisionada de traços sísmicos. Nesse contexto, $r(n)$ é a refletividade, $h(n)$ é a assinatura da fonte e $x(n)$ é o sismograma. Além das hipóteses previamente já mencionadas, Robinson também assume que a assinatura da fonte é necessariamente de fase mínima. Tal hipótese é crucial para o uso de um FEPPPU linear ótimo (no sentido de mínimo EQM de predição) na desconvolução de traços sísmicos devido ao fato de que essa estrutura somente produz filtros de fase mínima, portanto, capaz de aproximar apenas a inversa de sistemas de fase mínima.

Embora o FEPPPU linear seja amplamente utilizado na desconvolução de traços sísmicos, uma queda de desempenho pode ocorrer, pois a hipótese que a assinatura da fonte é de fase mínima nem sempre é observada em dados reais. Para tentar transpor as limitações deste método, este trabalho propõe o uso de FEPPPUs não lineares, mais precisamente usando redes neurais artificiais como preditores.

IV. REDES NEURAIAS

Redes Neurais Artificiais (RNAs) são modelos matemáticos inspirados no cérebro que possuem uma alta capacidade de armazenar e processar informação de forma massiva e paralela, utilizando unidades simples de processamento denominadas neurônios [8].

O neurônio artificial é a menor unidade que compõe uma rede neural e, quando conectado a outros neurônios, forma sinapses capazes de armazenar a informação que foi-lhes apresentada. A influência de uma sinapse é representada pelo peso sináptico associado a esta. A saída de um neurônio artificial pode ser modelada pela equação

$$h_k(n) = \varphi(\mathbf{w}_k^T \mathbf{u}(n) + b_k), \quad (6)$$

em que $\mathbf{u}(n) = [u_1(n) \ u_2(n) \ \dots \ u_M(n)]^T$ é o vetor de entradas, $\mathbf{w}_k = [w_{k1} \ w_{k2} \ \dots \ w_{kM}]^T$, $k = 1, 2, \dots, N$ é o vetor de pesos sinápticos, b_k é o bias e $\varphi(\cdot)$ é a função de ativação, usualmente, não linear. Note que a saída do neurônio é, portanto, uma função não linear das entradas, que são combinadas linearmente através do vetor de pesos sinápticos.

Neste trabalho, serão abordadas duas redes neurais, uma rede *feedforward* e uma recorrente, sendo elas: Extreme Learning Machines (ELMs) [9] e Echo-State Networks (ESNs) [10], respectivamente. A flexibilidade e a capacidade de adaptação e aprendizado destas redes neurais fazem com que as mesmas tornem-se uma opção atrativa no estudo de desconvolução preditiva de traços sísmicos. Além disso, como veremos, o treinamento dessas redes é relativamente simples, pois se reduz a um problema de regressão linear baseado no critério de mínimos quadrados.

A. Extreme Learning Machine

Extreme Learning Machine [9] é uma rede neural *feedforward* que possui uma única camada intermediária projetada de forma não supervisionada em que a saída realiza uma combinação linear das camadas anteriores. Como a ELM possui uma única camada intermediária, podemos considerá-la, estruturalmente, um caso particular de um Multilayer Perceptron (MLP) e, assim como esta, também possui capacidade de aproximação universal [8], porém a matriz de pesos sinápticos associada à camada intermediária de uma ELM é definida de forma esparsa e aleatória e mantida fixa após a inicialização do algoritmo. Neste trabalho, a matriz de pesos sinápticos foi definida de modo que seus elementos assumissem valores uniformemente distribuídos no intervalo $[-1, 1]$.

A concatenação das saídas dos neurônios da camada intermediária, resulta em um vetor \mathbf{h} da seguinte forma

$$\mathbf{h}(n) = \begin{bmatrix} h_1(n) \\ h_2(n) \\ \vdots \\ h_N(n) \end{bmatrix} = \begin{bmatrix} \varphi(\mathbf{w}_1^T \mathbf{u}(n)) \\ \varphi(\mathbf{w}_2^T \mathbf{u}(n)) \\ \vdots \\ \varphi(\mathbf{w}_N^T \mathbf{u}(n)) \end{bmatrix} = \varphi\left(\mathbf{W}_{in}^T \mathbf{u}(n)\right)$$

em que $b = 0$ e, por este motivo, iremos omiti-lo.

A saída da rede é dada pela combinação linear das saídas dos neurônios da camada intermediária

$$y(n) = \mathbf{w}_{out}^T \mathbf{h}(n)$$

em que \mathbf{w}_{out}^T é o vetor dos pesos sinápticos da camada de saída.

Por conta de não ocorrer o ajuste dos pesos sinápticos da camada intermediária, a determinação dos coeficientes ótimos da camada de saída resume-se a um problema de regressão linear, caso o critério usado seja o de mínimo EQM. Essa característica faz da ELM uma escolha interessante na desconvolução preditiva visto que esta possui capacidade de aproximação universal unida à simplicidade de um treinamento baseado na solução de um sistema linear.

B. Echo State Network

Echo-State Network (ESN) é uma rede neural que também possui uma única camada intermediária, porém com realimentação. O diferencial da ESN está na sua camada intermediária, denominada reservatório de dinâmicas, que quando arquitetada de modo a cumprir algumas propriedades, apresenta estados de eco. Basicamente, a diferença entre a ELM e a ESN consiste na realimentação que esta última apresenta e, urge sabermos se esta característica resultará em resultados melhores.

Seja $\mathbf{u}(n) = [u_1(n) u_2(n) \dots u_N(n)]^T$ o vetor de entradas da rede e $\mathbf{W}^{in} \in R^{N \times K}$ a matriz dos pesos sinápticos da camada intermediária, o vetor contendo as saídas dos neurônios da camada intermediária é dado por

$$\mathbf{h}(n+1) = \varphi(\mathbf{W}^{in} \mathbf{u}(n+1) + \mathbf{W} \mathbf{h}(n)), \quad (7)$$

em que $\mathbf{W} \in R^{N \times N}$ é a matriz de pesos de realimentação que define a dinâmica do reservatório. A saída da rede é dada pelo produto entre Equação (7), denominada Equação dos Estados de Transição, e o vetor de pesos sinápticos da saída dos neurônios, ou seja

$$y(n) = \mathbf{w}_{out}^T \mathbf{h}(n). \quad (8)$$

A matriz de dinâmica de reservatórios \mathbf{W} está presente apenas na ESN. Ela é projetada de maneira não supervisionada de modo a atender algumas propriedades que garantam a existência de estados de eco [10], [11], [12].

C. Treinamento das redes neurais

O treinamento da ELM e da ESN é feito de maneira equivalente, em outras palavras, ambas requerem a determinação de vetor de pesos \mathbf{w}_{out} . A solução ótima é obtida pelo critério de mínimos quadrados e é dada por

$$\mathbf{w}_{out}^T = \mathbf{H}^+ \mathbf{d},$$

em que \mathbf{H} é a matriz em que cada linha corresponde ao vetor de saídas dos neurônios, \mathbf{d} é o vetor que contém o sinal de referência e $(\cdot)^+$ é o operador da pseudo-inversa de Moore-Penrose.

V. RESULTADOS

Estudos anteriores no âmbito de equalização mostraram que o uso de um FEPPPU não linear é capaz de aproximar a inversa de um canal de fase mista [3], [4], [5]. Estes resultados despertaram o interesse de investigarmos o uso de um FEPPPU não linear na desconvolução de traços sísmicos. Em essência, a diferença entre o problema de equalização e o de desconvolução sísmica está nas características do sinal a ser recuperado. No problema de equalização de canais de comunicação digital, $r(n)$ corresponde ao sinal transmitido que é antiesparso e composto por uma sequência de símbolos i.i.d., equiprováveis e pertencentes a um alfabeto finito, ou seja, sua amplitude pode assumir um número restrito de valores. Por outro lado, na desconvolução sísmica, $r(n)$ representa a refletividade que é modelada como um sinal branco, esparsos e cuja amplitude pode assumir qualquer valor dentro de uma faixa contínua. Nesse experimento, nosso objetivo é avaliar o efeito da diferença entre as características dos sinais a serem recuperados no desempenho da desconvolução preditiva não linear, verificando se ela é adequada ao sinal sísmico. Vamos considerar que o ruído é nulo para que ele não interfira na análise da capacidade do FEPPPU de remover as distorções no sinal. Primeiro, analisaremos o problema de equalização para canais de fase mínima e mista. Depois, repetiremos os experimentos no contexto de desconvolução sísmica, alterando apenas o sinal de entrada do sistema, que passará a ter as características de uma refletividade. O diagrama mostrado na Fig. 1 sumariza o experimento.






Fig. 1: Diagrama de um sistema no qual o FEPPPU é o operador desconvolucional em que o sinal de entrada pode ser tanto um sinal de comunicação digital quanto uma refletividade.

Um sistema de comunicação digital tem por objetivo transmitir a informação entre a fonte emissora e a receptora. Tal informação é codificada e é representada por símbolos equiprováveis pertencentes a um alfabeto finito que, neste experimento, será constituído pelo conjunto $\{-1, 1\}$. Como explicitado na Fig. 1, a sequência $r(n)$ representa o sinal transmitido que é distorcido pelo canal $h(n)$ de modo que $x(n)$ é a informação distorcida que chega ao receptor. Para que $r(n)$ seja recuperado, usa-se um filtro equalizador que, neste trabalho, será um FEPPPU. A estimativa do sinal transmitido é obtida a partir da quantização da saída do FEPPPU, de modo que $\hat{r}(n) = \text{sign}(y(n))$. Assim, se $\hat{r}(n)$ for idêntico a $r(n)$,



(a) Estimativa Linear.

(b) Estimativa ELM.



(c) Estimativa ESN.


Fig. 2: Os pontos na cor preta representam os valores que a sequência transmitida pode assumir, enquanto que, os que estão em azul são as estimativas geradas pelos FEPPPU não lineares e linear em que o canal é de fase mínima.

a informação é recuperada perfeitamente e a taxa de erro é nula.

No primeiro cenário, geramos o sinal $x(n)$ distorcido pelo canal de fase mínima cuja função de transferência foi $H(z) = 1 + 0,3z^{-1} - 0,5z^{-2}$. Os parâmetros ótimos dos equalizadores foram obtidos através da minimização do erro quadrático médio, conforme discutido nas seções II e IV-C. Para o FEPPPU linear, usamos $M = 10$, e, para a ELM e ESN, usamos $M = 3$ e $N = 22$ neurônios. Tais parâmetros foram obtidos empiricamente com base no desempenho das estruturas de filtragem (semelhança da refletividade estimada em comparação com a original) em simulações. As estimativas produzidas pelos três equalizadores, representadas em azul nas Figuras 2a, 2b e 2c, giram em torno dos valores da sequência usada como referência, em preto. Após a quantização destas estimativas, a taxa de erro foi nula, para os três equalizadores. Esse resultado era esperado uma vez que trata-se de um canal de fase mínima, cenário em que as três estruturas têm o potencial de produzir uma boa inversa do canal.


Mudando o cenário para um canal de fase mista, em que $H(z) = 0,5 + 0,7z^{-1} - 0,15z^{-2}$, e mantendo a mesma configuração do número de coeficientes, entradas e neurônios usados no cenário anterior, os resultados obtidos foram os mostrados nas Figuras 3a, 3b e 3c. Nesse caso, o FEPPPU linear falhou e as redes neurais foram capazes de recuperar a sequência transmitida perfeitamente após a quantização da saída do equalizador de modo que a taxa de erro foi nula. Esse resultado condiz com o que foi exposto pela literatura, uma vez que é necessário um FEPPPU não linear para equalizar um canal de fase mista [13], [3], [4].

Confirmado que as estruturas propostas funcionam no problema de equalização, vamos mudar o sinal de entrada, $r(n)$, do sistema mostrado na Fig. 1 para a refletividade sintética



(a) Estimativa Linear.

(b) Estimativa ELM.



(c) Estimativa ESN.

Fig. 3: Nas figuras acima, os pontos na cor preta representam os valores que a sequência transmitida pode assumir, enquanto que, os que estão em azul são as estimativas geradas pelos FEPPPU não lineares e linear em que o canal é de fase mista.

mostrada nas figuras 4 e 5, passando, dessa forma, para o problema de desconvolução sísmica. Note que a refletividade possui eventos sísmicos próximos que são sobrepostos pela ação da assinatura da fonte, constituindo um cenário desafiador para a desconvolução.




Fig. 4: Refletividade estimada de uma wavelet de fase mínima, sem ruído aditivo

Utilizando a assinatura de fase mínima, $H(z) = 1 + 0,3z^{-1} - 0,5z^{-2}$, FEPPPU linear com $M = 15$, ELM com $M = 10$ e $N = 40$, e ESN com $M = 10$ e $N = 65$, foram obtidos o sismograma e refletividades estimadas mostradas na

Fig. 4. Os resultados da ELM e ESN representam a média de 3000 realizações. Os parâmetros M e N foram determinados empiricamente por meio de simulações. Nesse cenário, os resultados para as três estruturas foram muito semelhantes e todas produziram uma boa estimativa da refletividade, o que era esperado, uma vez que a assinatura da fonte é de fase mínima.

Mudando para a assinatura de fase mista, $H(z) = 0,5 + 0,7z^{-1} - 0,15z^{-2}$, e utilizando um FEPPPU linear com $M = 14$, ELM com $M = 10$ e $N = 62$, e ESN com $M = 2$ e $N = 45$, obtivemos os resultados mostrados na Fig. 5. Novamente, as estimativas das redes neurais representam a média entre 3000 realizações do experimento.




Fig. 5: Refletividade estimada de uma wavelet de fase mista, sem ruído aditivo

A estimativa do FEPPPU linear não comprimiu $h(n)$. Pelo contrário, a assinatura da fonte foi ampliada de modo que o resultado aumentou a sobreposição entre os eventos, piorando o sismograma original. Isso se deve ao fato do FEPPPU linear ótimo ser um filtro necessariamente de fase mínima que é incapaz de aproximar adequadamente a inversa de um sistema de fase mista.

Por outro lado, tanto o FEPPPU baseado na ELM quanto na ESN obtiveram bons resultados. Embora a recuperação da refletividade não seja perfeita para ambos, pois são observadas algumas distorções de amplitude relativa entre eventos e criação de artefatos, os resultados são muito melhores do que os obtidos através do FEPPPU linear. Chama a atenção principalmente o desempenho da ESN, que utiliza apenas duas entradas no preditor. Cabe realizarmos estudos em problemas cenários complexos em relação aos que já foram investigados

usando tal estrutura, pois a realimentação existente nesta parece ser interessante para o problema.

VI. CONCLUSÕES

Neste artigo, propomos o uso de um FEPPPU não linear na desconvolução sísmica, em que as redes neurais ELM e ESN foram utilizadas como preditores. Usualmente, para recuperar a refletividade, usa-se o método de desconvolução preditiva linear, que apresenta limitações quanto à inversão de sistemas de fase mista.

Estudos anteriores no âmbito de equalização de canais de comunicação mostraram que um FEPPPU não linear é capaz de aproximar a inversa de um canal de fase mista e, como a única diferença do problema de equalização em relação à desconvolução sísmica é a característica do sinal, aplicamos o FEPPPU não linear em um sismograma cuja assinatura é de fase mista. Observamos que as estimativas da refletividade geradas pelos FEPPPUs não lineares foram muito melhores que a do linear. Apesar de haver distorções e artefatos criados durante a filtragem, foi possível recuperar os eventos próximos que originalmente estavam sobrepostos pela assinatura da fonte.

Os resultados preliminares que foram obtidos mostram-se promissores, principalmente os da ESN, sinalizando que, além da não linearidade, a recorrência presente nessa estrutura pode ser benéfica ao problema. Estudos em cenários mais complexos e em dados reais são necessários para comprovar a eficácia da técnica proposta.

REFERÊNCIAS

- [1] J. M. T. Romano, R. Attux, C. C. Cavalcante, and R. Suyama, *Unsupervised signal processing: channel equalization and source separation*. CRC Press, 2011.
- [2] O. Yilmaz, *Seismic data analysis: processing, inversion and interpretation of seismic data*, vol. 1. SEG Books, 2001.
- [3] R. Ferrari, *Equalização de canais de comunicação digital baseada em filtros fuzzy*. PhD thesis, Faculdade de engenharia elétrica e de computação, Universidade de Campinas, 2005.
- [4] R. Ferrari, *Equalização preditiva e otimização de sistemas DSL por gerenciamento espectral e processamento MIMO*. PhD thesis, Faculdade de engenharia elétrica e de computação, Universidade de Campinas, 2011.
- [5] A. K. Takahata, E. Z. Nadalin, R. Ferrari, L. T. Duarte, R. Suyama, R. R. Lopes, J. M. T. Romano, and M. Tygel, "Unsupervised processing of geophysical signals," *IEEE Signal Processing Magazine*, vol. 27, pp. 27–35, 2012.
- [6] S. Haykin, *Adaptive filter theory*. Prentice Hall, 2001.
- [7] E. A. Robinson, *Predictive decomposition of time series with applications to seismic exploration*. PhD thesis, Massachusetts Institute of Technology, 1954.
- [8] S. S. Haykin et al., *Neural networks and learning machines/Simon Haykin*. New York: Prentice Hall, 2009.
- [9] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, no. 1-3, pp. 489–501, 2006.
- [10] H. Jaeger, "The "echo state" approach to analysing and training recurrent neural networks-with an erratum note," *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report*, vol. 148, no. 34, p. 13, 2001.
- [11] M. Lukoševicius and H. Jaeger, "Overview of reservoir recipes," tech. rep., Technical report, 2007.
- [12] I. B. Yildiz, H. Jaeger, and S. J. Kiebel, "Re-visiting the echo state property," *Neural networks*, vol. 35, pp. 1–9, 2012.
- [13] C. C. Cavalcante, J. R. M. F., B. Dorizzi, and J. C. M. Mota, "A neural predictor for blind equalization of digital communications systems," in *Proceedings of the 2000 Adaptive Systems for Signal Processing, Communications and Control Symposium*, 2000.