

Bolsista: Douglas Mancini Consolaro
e-mail: douglas.consolaro@gmail.com
Orientador: Prof. Dr. Fernando José Von Zuben
e-mail: vonzuben@dca.fee.unicamp.br

Laboratório de Bioinformática e Computação Bio-Inspirada (LBIc) Faculdade de Engenharia Elétrica e de Computação (FEEC),
Instituto de Matemática, Estatística e Computação Científica (IMECC).
Agência Financiadora : CNPq.
Palavras-chave: Redes Neurais Artificiais - Inteligência Computacional -Processamento de Sinais e Controle.

INTRODUÇÃO

Este projeto visa o estudo de comportamento dinâmico não-linear via redes neurais artificiais com estados de eco. Este novo modelo de arquitetura de rede neural apresenta uma metodologia própria para a sua implementação, a qual se baseia na entropia dos estados de eco, que correspondem à ativação dos neurônios recorrentes, responsáveis pela produção da saída da rede neural. Com o foco em problemas não-lineares de identificação de sistemas e filtragem adaptativa, tem-se por objetivo compreender e implementar todas as etapas envolvidas com base nesta nova arquitetura e metodologia de rede neural. As aplicações consideradas são de fundamental importância para as áreas de controle e processamento de sinais, e os resultados obtidos permitem validar a metodologia, a qual se mostra competitiva quando comparada a outras já desenvolvidas e consolidadas.

METODOLOGIA

A formulação de uma Rede Neural com Estados de Eco (RNEE) discreta no tempo se baseia em um conjunto de dados de entrada $u(n)$, um conjunto de estados internos $x(n)$ e um conjunto de sinais de saída $y(n)$. Os pesos das conexões são dados por meio de uma matriz W_{in} (conexões entre as unidades de entrada e as internas), de uma matriz W (conexões entre as unidades internas), de uma matriz W_{out} (conexões das unidades internas com as de saída), e de uma matriz W_{back} (conexões que ligam a saída aos neurônios internos).

A dinâmica dos Elementos de Processamento (PE) internos obedece ao seguinte modelo:

$$X(n) = f(W_{in} \cdot u(n) + W \cdot x(n) + W_{back} \cdot y(n)), \quad (1)$$

onde $f = (f_1, f_2, \dots, f_n)$ contém as funções de ativação dos PE's, que neste projeto, são sempre tangentes hiperbólicas. A saída da rede é computada através da expressão:

$$Y(n) = f_{out}(W_{out} \cdot [u(n), x(n), y(n)]), \quad (2)$$

onde $f_{out} = (f_{out_1}, f_{out_2}, \dots, f_{out_n})$ são as funções de ativação das unidades de saída e $[u(n), x(n), y(n)]$ corresponde à concatenação dos vetores de entrada, estados internos e saída. As matrizes de pesos são mantidas fixas, exceto a matriz de pesos da saída W_{out} , que deverá ser ajustada a fim de se minimizar o erro quadrático médio (MSE - mean squared error) entre o sinal desejado e o produzido pela rede.

Inovações a esta metodologia clássica foram incorporadas, as quais são a utilização da estratégia de Análise do Componente Principal (PCA) nos estados do reservatório e um filtro de Volterra como combinador das dinâmicas dos estados de eco. A sintetização de uma rede híbrida, a partir da fusão da metodologia "adaptada" de RNEE e o princípio de algoritmos genéticos, também ilustram o cenário de inovações promissoras para as RNEE.

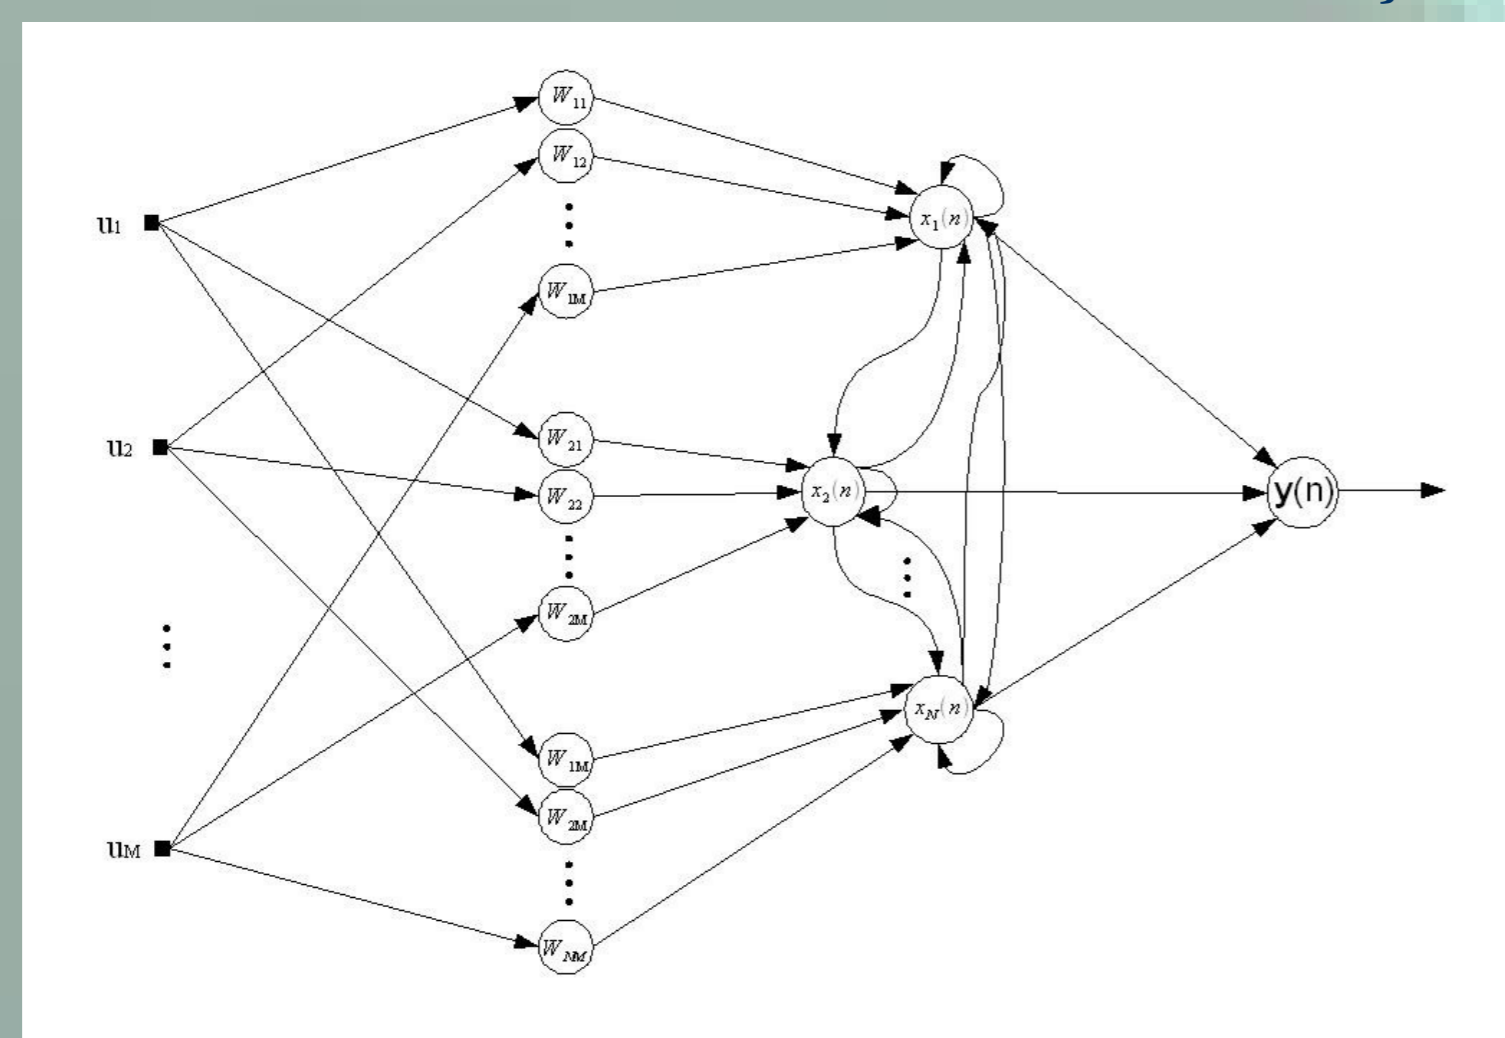


Figura 1: Exemplo de uma rede neural com estados de eco.

RESULTADOS E DISCUSSÕES

Destacamos aqui os principais resultados obtidos para os problemas de Equalização, Predição com Equalização e Identificação de sistemas.

O problema de identificação de sistemas apresenta-se como o pano de fundo para o estudo comparativo entre duas arquiteturas: uma rede neural recorrente (RNR) adaptada com o auxílio de um método de otimização baseado nas derivadas da função custo de erro quadrático médio e uma RNEE projetada segundo a metodologia de *Ozturk et al. (2007)*. Essa comparação, de certa forma, representa uma avaliação de como a RNEE se situa relativamente a "soluções recorrentes padrão".

Rede Neural Recorrente			Rede Neural com Estados de Eco		
Neurônios	Erro Treino	Erro Teste	Neurônios	Erro Treino	Erro Teste
1	0,1	1,6	1	0,67	0,67
7	0,01	0,01	7	0,01	0,01
40	0,01	0,03	40	8,57E-07	9,74E-07

Tabela 1: Dados comparativos de desempenho para uma rede neural recorrente e uma com estados de eco, para um problema de identificação de sistemas.

Aplicação de redes neurais com estados de eco ao problema de equalização supervisionada e não-supervisionada (baseada em predição) de canais é, até onde sabemos, inédita, o que por si só justificaria os resultados. Além do mais, tais cenários também servirão como um pano de fundo para a comparação entre a RNEE de *Ozturk et al. (2007)* (doravante referida apenas como RNEE), a RNEE proposta (que será chamada de RNEEP) e a rede híbrida.

A análise dos resultados para equalização supervisionada indicou, primeiramente, que o uso de redes neurais com estados de eco no papel de equalizadores é não só viável, mas também promissora.

	Modelo Clássico (RNEE)	Modelo Proposto (RNEEP)
Canal	Linear $H(z) = 0.5 + z^{-1}$	Linear $H(z) = 0.5 + z^{-1}$
Neurônios	60	40
Erro Treino	0,008703	8,8320E-05
Erro Teste	0,010632	0,00012516

Tabela 2: Resultados obtidos para o problema de Equalização. Os valores do erro de treino e teste são baseados numa média de 10 simulações. O sinal de entrada é unitário e sem atraso.

Canal linear $H(z) = 0.5 + 0.71z^{-1} + 0.5z^{-2}$	Neurônios	Erro Treino
Rede 1	60	5,74E-02
Rede 2	40	3,01E-04
Rede 3	5	7,42E-05

Tabela 4: As redes 1, 2 e 3 representam os modelos de RNEE clássico, o de RNEE adaptado e a arquitetura híbrida, respectivamente. A rede 2 possui uma configuração de 10 componentes para o PCA.

	Modelo Clássico (RNEE)	Modelo Proposto (RNEEP)
Canal	Linear $H(z) = 1 + z^{-1}$	Linear $H(z) = 1 + z^{-1}$
Neurônios	60	40
Erro Treino	0,02882	0,01131
Erro Teste	0,03194	0,01302

Tabela 3: Resultados obtidos para o problema de Predição com Equalização. Os valores do erro de treino e teste são baseados numa média de 10 simulações. O sinal de entrada é unitário e sem atraso.

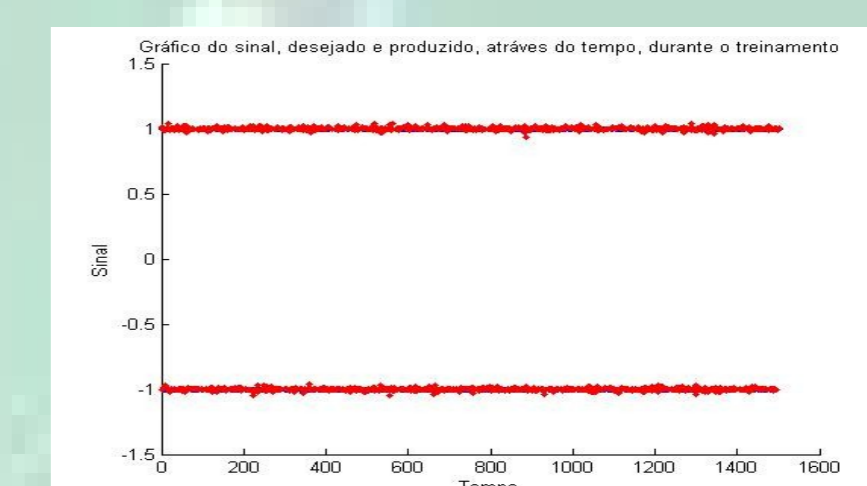


Figura 2: Gráfico de decisão para a equalização de um canal linear $H(z) = 0.5 + z^{-1}$, com entrada unitária, sem atraso, com filtro de Volterra e com 6 componentes para o PCA. Seu erro de treino é 0,008700.

CONCLUSÃO

Este trabalho, cujo objetivo inicial era validar e compreender a estrutura de funcionamento de uma RNEE, se supera do ponto de vista do surgimento de novas idéias promissoras que agregaram um valor extra a tal estrutura de RNEE, elevando-a a um novo nível de desempenho junto aos problemas abordados.

Na área de processamento de sinais dois problemas clássicos foram avaliados, equalização e predição com equalização. Para o problema de equalização, o uso de uma RNEE se mostrou inovador e também válido. Mas seguramente o maior avanço jaz sobre a conquista de excelentes resultados a partir das novas ferramentas propostas, tanto a RNEE modificada como a rede híbrida.

Esse novo paradigma junto às RNEE é fruto da adição da técnica do PCA à saída do reservatório de dinâmicas e a implementação de um filtro de Volterra na saída da rede. Tais estratégias somaram forças no poder de extração de informação dos estados de eco e no poder de tratamento de comportamentos não lineares, características essas essenciais na ideologia das RNEE.

REFERÊNCIA

Ozturk, M.C., Xu, D., Principe, J.C. (2007). Analysis and Design of Echo State Networks. *Neural Computation*, vol. 19, pp. 111-138.

AGRADECIMENTOS

Ao Prof. Fernando J. Von Zuben por me acolher e me guiar em meus primeiros passos no universo da pesquisa científica, onde mostrou-me o caminho das pedras para uma formação científica de excelência.

Ao Prof. Romis R. de Faissol Attux por toda dedicação extremamente carinhosa e companheira que exerceu junto a formalização desta pesquisa, "sustentando-me sobre seus ombros para que eu pudesse enxergar além dos obstáculos vislumbrando um novo mundo".

Ao CNPq por financiar este projeto e aos demais pesquisadores que contribuíram com esta pesquisa.