

# Identificação e Controle de um Sistema de Troca de Calor entre Vapor e Líquido Saturado: uma Abordagem Híbrida<sup>\*</sup>

Pedro H. L. S. P. Domingues<sup>\*</sup> Marley M. B. R. Vellasco<sup>\*\*</sup>  
Ricardo Tanscheit<sup>\*\*\*</sup>

<sup>\*</sup> Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro, RJ, (e-mail: phd.engmec@gmail.com).

<sup>\*\*</sup> Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, RJ, (e-mail: marley@ele.puc-rio.br).

<sup>\*\*\*</sup> Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, RJ, (e-mail: ricardo@ele.puc-rio.br).

**Abstract:** The present work proposes i) the extraction of the dynamics of a liquid-saturated steam heat exchanger through a black-box approach, considering multiobjective optimization of an Echo State Network (ESN) hyperparameters based on performance and complexity metrics and ii) the application of a fuzzy control on the ESN obtained to follow a temperature trajectory. Results showed that the generated model can be controlled and, when compared with a model obtained in an approach with only performance optimization, a similar performance is achieved but with a significant model complexity reduction.

**Resumo:** O presente trabalho propõe i) a extração da dinâmica de um trocador de calor entre líquido e vapor saturado por meio de uma abordagem *black-box*, onde se consideram métricas de desempenho e complexidade para a otimização multiobjetivo dos hiperparâmetros de uma *Echo State Network* (ESN); e ii) a aplicação de um controle *fuzzy* na ESN obtida para seguir uma trajetória de temperatura. Os resultados mostraram que o modelo gerado pode ser controlado e que quando comparado com um modelo obtido em uma abordagem de otimização apenas do desempenho, consegue-se um desempenho semelhante, mas com significativa redução da complexidade do modelo.

**Keywords:** Systems Identification; Recurrent Neural Network; Echo State Networks; Multiobjective Optimization; Nondominated Sorting Genetic Algorithm II; Fuzzy Control.

**Palavras-chaves:** Identificação de Sistemas; Redes Neurais Recorrentes; Rede Neural Echo State; Otimização Multiobjetivo; Nondominated Sorting Genetic Algorithm II; Controle Fuzzy.

## 1. INTRODUÇÃO

A identificação de sistemas é a área do conhecimento que busca desenvolver métodos capazes de extrair modelos matemáticos que representem a dinâmica de um determinado sistema, permitindo a compreensão, descrição e simulação do mesmo. Resumidamente, duas abordagens são previstas para a identificação de sistemas: i) a *grey-box*, onde um modelo parcial ou completo é criado a partir de modelagem matemática e princípios físicos, seguido do ajuste de seus parâmetros a partir dos dados; e ii) a *black-box*, que busca excitar o sistema para coletar dados de entrada e saída e construir um modelo matemático a partir deles. Dado que a abordagem *grey-box* depende de informações do sistema dinâmico que, por vezes, são complexos o suficiente para impossibilitarem a sua implementação, a abordagem

*black-box* sobressai em termos de facilidade de execução, apresentando resultados semelhantes (Billings, 2013).

As redes neurais artificiais (RNAs) buscaram inspiração na arquitetura e processo de aprendizado do cérebro, onde várias unidades de processamento simples (i.e. neurônios) são distribuídas em camadas. Essa estrutura confere uma capacidade natural de aprendizado a partir de dados (i.e. experiência) e configura as RNAs como aproximadores universais (Cybenko, 1989). Assim, as RNAs são capazes de aproximar as mais diversas classes de funções, fazendo com que sejam modelos ideais para a identificação de sistemas complexos e não lineares através da abordagem *black-box* (Haykin, 2010; Géron, 2019). Em essência, as RNAs podem ser do tipo i) *feedforward* (RNF), onde há a propagação de informação somente da entrada para a saída do modelo; ou ii) recorrentes (RNRs), onde as saídas de cada camada podem ser utilizadas para realimentar o modelo. Apesar das RNFs serem mais utilizadas pela comunidade científica, as RNRs são mais indicadas para problemas com dependência temporal ou de identificação *black-box*, já que a presença da recorrência nas RNRs aumenta a

<sup>\*</sup> O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação de Amparo à Pesquisa do Rio de Janeiro (FAPERJ).

complexidade do modelo e permite a representação direta da dimensão temporal dos dados utilizados na abordagem. As RNFs dependem de *delays* explícitos, especificados pelo projetista, para representar a dependência temporal do problema (Géron, 2019; Schrauwen et al., 2007).

Proposta em Jaeger (2001), a *Echo State Network* (ESN) é um tipo de RNR que apresenta um reservatório de neurônios esparsos e aleatoriamente conectados para substituir as camadas ocultas. As ESNs vêm se destacando em problemas de identificação de sistemas frente às RNRs tradicionais por i) apresentarem um treinamento mais simples, já que mesmo demandando o ajuste de hiperparâmetros, apenas os pesos de saída são ajustados; e ii) apresentarem resultados com maior acurácia, no geral (Yao et al., 2018). No entanto, as ESNs são sensíveis aos seus hiperparâmetros, carecendo de um ajuste fino para atingir seu melhor desempenho (Paiva, 2018). A sintonia de hiperparâmetros, por sua vez, pode ser encarada como um problema de otimização. Em Paiva (2018), buscando automatizar o ajuste da ESN, utilizou-se o algoritmo evolucionário *Real Coded Quantum-Inspired Evolutionary Algorithm* (QIEA-R) para encontrar os hiperparâmetros da rede que minimizassem a raiz do erro médio quadrático (RMSE). Entretanto, uma abordagem de otimização multiobjetivo (OMO) em que se considera, além da acurácia, a complexidade do modelo, permitiria buscar um modelo com uma melhor relação entre simplicidade da arquitetura e desempenho.

Amplamente utilizados em diversos ciclos e sistemas industriais, trocadores de calor são exemplos de sistemas dinâmicos não lineares, cuja extração do modelo permite a simulação e facilita a tomada de decisão no planejamento de manobras, na gestão dos processos associados à planta e constitui importante ferramenta na sintonia de controladores. Por se tratar de um sistema complexo e não linear, controladores lineares tradicionais como o proporcional integral derivativo (PID) até podem ser utilizados, mas são geralmente superados por controladores não lineares (e.g. Peralez et al. (2013); Yebi et al. (2017)) (Xu et al., 2019). Todavia, controladores não lineares apresentam arquitetura complexa, tornando sua implementação difícil ou impraticável. Dado esse panorama, destaca-se como alternativa o controle *fuzzy*, que é capaz de traduzir regras lógicas em um mapeamento não linear (Ibarra and Webb, 2016).

O presente trabalho busca realizar a identificação *black-box* de um trocador de calor entre líquido e vapor saturado através do ajuste de uma RNR do tipo ESN, de modo que seja possível ajustar um controlador *fuzzy* com base no modelo obtido, constituindo uma abordagem híbrida. Buscando atingir esse fim, propõe-se a OMO de uma ESN com o algoritmo evolucionário *nondominated sorting genetic algorithm II* (NSGA-II) para o ajuste automático de seus hiperparâmetros, considerando métricas de desempenho (i.e. RMSE) e complexidade (i.e. número de neurônios no reservatório) da rede.

O artigo está dividido da seguinte forma: a Seção 2 introduz o problema em estudo, a arquitetura da ESN, o conceito de optimalidade de Pareto e o algoritmo utilizado para a OMO; a Seção 3 apresenta o *framework* de identificação de sistemas e implementação do controle *fuzzy*;

e, por fim, as Seções 4 e 5 apresentam os resultados e conclusões do trabalho.

## 2. FUNDAMENTAÇÃO TEÓRICA

A presente seção trata de aspectos teóricos do problema de identificação de sistemas proposto no trabalho, descrevendo o estudo de caso na Seção 2.1, introduzindo o modelo de ESN utilizado para identificação do sistema na Seção 2.2 e revisando conceitos de OMO, junto à apresentação do algoritmo de otimização NSGA-II, na Seção 2.3.

### 2.1 Descrição do Problema

O estudo de caso é constituído por um trocador como o apresentado na Figura 1, onde água líquida é aquecida por vapor saturado através da troca realizada no tubo de cobre. O processo é caracterizado por um comportamento não linear de fase não mínima, constituindo-se em um desafio para a sintonia de controladores (Bittanti and Piroddi, 1997). O conjunto de dados é livre para uso e foi obtido no repositório Moor (2018), contando com 4.000 dados simulados de vazão de líquido de entrada  $q(t)$  ( $m^3/s$ ) e temperatura do líquido de saída  $T(t)$  ( $^{\circ}C$ ), considerando tempo de amostragem de 1 s e temperatura constante na entrada de líquido e vapor saturado. Os dados foram divididos em três conjuntos (Paiva, 2018): i) treinamento (1 a 550); ii) validação (551 a 1000); e iii) teste (1001 a 4000).




Figura 1. Representação esquemática de um trocador de calor do tipo líquido-vapor saturado (adaptado de Bittanti and Piroddi (1997)).

### 2.2 Echo State Networks

A arquitetura de uma rede neural do tipo ESN é apresentada na Figura 2. Basicamente, as redes ESN apresentam três camadas: i) a entrada  $u(k)$ , que compreende um vetor de  $H$  valores; ii) o reservatório dinâmico com  $N$  estados  $x(k)$ , onde há  $N^2$  pesos ligando cada estado aos demais e a ele mesmo, considerando o hiperparâmetro de esparsidade  $c_W$ , que define o percentual de ligações não nulas; e iii) a saída  $y(k)$ , constituída por um vetor de  $L$  valores (Jaeger, 2001).

Como ilustrado na Figura 2, há uma distribuição de pesos entre as camadas, sendo  $W_{in}$ ,  $W$ ,  $W_{in,out}$ ,  $W_{res,out}$  e  $W_{back}$ , os pesos de entrada, internos, de transição direta entrada-saída, da saída do reservatório para a saída da rede

e do *feedback*, respectivamente. Os pesos  $W_{in}$  e  $W_{back}$  são obtidos a partir do produto dos hiperparâmetros fatores de escala de entrada  $s_{in}$  e de *feedback*  $s_{back}$  pelas matrizes de pesos aleatórios  $W_0^{in}$  e  $W_0^{back}$ , respectivamente, afetando, portanto, a não linearidade do modelo. Os pesos internos  $W$  são obtidos da multiplicação do hiperparâmetro raio espectral  $\rho_W$  pela razão  $\frac{W_0}{\rho(W_0)}$ , onde  $W_0$  é uma matriz de pesos aleatórios e  $\rho(W_0)$  é o autovalor de  $W_0$  que tem maior valor absoluto. Logo,  $\rho_W$  define a dinâmica de influência das entradas na rede. Os pesos de saída  $W_{out}$  são obtidos pela concatenação  $[W_{in,out}, W_{res,out}]$ , sendo estes os únicos pesos da rede que são treinados. Definida a arquitetura, a relação entre os estados  $x(k)$  e as saídas  $y(k)$  é dada pelas equações a seguir (Jaeger, 2001; Lukoševičius, 2012):

$$x(k) = (1 - \alpha)x(k - 1) + \alpha f^{res}(W_{in}u(k) + Wx(k - 1) + W_{back}y(k - 1)) \quad (1)$$

$$y(k) = f^{out}(W_{out}[u(k)^T x(k)^T]^T) \quad (2)$$

onde  $\alpha \in (0, 1]$  é o hiperparâmetro de taxa de vazamento, que define a dinâmica da discretização no tempo;  $f^{res}(\cdot)$  e  $f^{out}(\cdot)$  são as funções de ativação para cada um dos  $N$  estados do reservatório e das  $L$  unidades da camada de saída, respectivamente;  $T$  é operador de transposição da matriz; e consideram-se as condições iniciais  $x(0) = 0$  e  $y(0) = 0$ .

Por fim, o treinamento da rede é realizado segundo a sequência a seguir: i) as matrizes  $W_{in}$ ,  $W$  e  $W_{back}$  são geradas; ii) os estados  $x(k)$  do reservatório são calculados para cada entrada  $u(k)$  por meio da equação (1); iii) considerando apenas as entradas  $u(k)$ , estados  $x(k)$  e *targets*  $d(k)$  obtidos quando  $k \geq T_0$ , montam-se iterativamente as matriz  $M$  e  $D$  pela adição de uma nova linha com a concatenação  $[u(k), x(k)]$  em  $M$  e com  $d(k)$  em  $D$ , onde  $T_0$  é o *washout time*, ou seja, um período transitório em que a rede ainda está “esquecendo” seus estados iniciais e é, portanto, desconsiderado; iv) por fim, os pesos de saída  $W_{out}$  são obtidos pela seguinte expressão:

$$W_{out} = (pinv(M)D)^T \quad (3)$$

onde  $pinv(\cdot)$  é o operador que calcula a matriz pseudoinversa do seu argumento.

### 2.3 Otimização Multiobjetivo

Problemas de OMO não utilizam o mesmo conceito de ótimo de otimização com um único objetivo, já que as soluções obtidas apresentam diferentes relações de troca entre os objetivos, inviabilizando a comparação direta entre elas (Coello et al., 2007). Assim, a presente seção busca introduzir o conceito de ótimo para OMO e o funcionamento do algoritmo utilizado.

A *Teoria da Optimalidade de Pareto* é o conceito de ótimo mais comum para problemas de OMO, sendo baseada nas seguintes definições: i) dominância de Pareto: um vetor solução  $x^1$  é dito dominador de  $x^2$  ( $x^1 \succ x^2$ ) se e somente se  $x^1$  é melhor avaliado do que  $x^2$  em pelo menos um objetivo e, no mínimo, igualmente bom a  $x^2$  nos demais; ii) ótimo de Pareto: um vetor solução  $x^*$  é

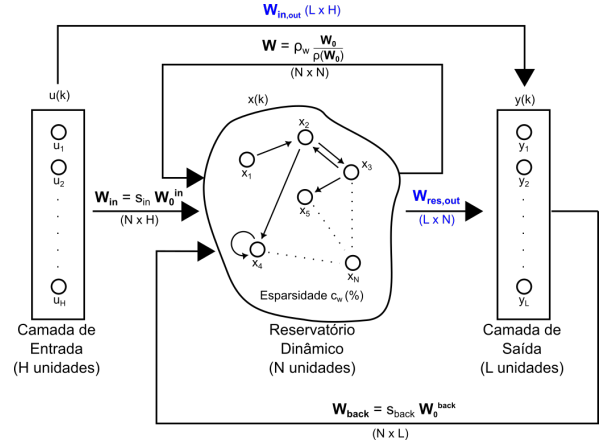


Figura 2. Representação esquemática da arquitetura de uma *Echo State Network* (adaptado de (Jaeger, 2001)).

dito ótimo de Pareto (ou não dominado) se não há outra solução no espaço de busca que domine  $x^*$ ; iii) conjunto de Pareto: é a representação dos ótimos de Pareto no espaço de decisões; e iv) frente de Pareto: é a representação das soluções não dominadas no espaço de objetivos. A formulação matemática das definições apresentadas está presente em (Coello et al., 2007).

O *Nondominated Sorting Genetic Algorithm II* foi proposto em Deb et al. (2002) como um algoritmo genético (AG) rápido, elitista e multiobjetivo que se difere do AG tradicional (Goldberg, 1989) na forma como as soluções são selecionadas para compor a nova população. O processo de seleção considera a dominância de Pareto para classificar as soluções (i.e. colocar em um *rank*), permitindo a representação de múltiplos objetivos com um único valor, o que confere maior desempenho ao método. A nova população é então preenchida com as soluções de menor *rank*. No entanto, não havendo espaço para todas as soluções de um mesmo *rank*, o operador de *crowding distance* é acionado e, para cada solução deste *rank* (com exceção das extremas), é traçado um cuboide entre as soluções vizinhas mais próximas; selecionam-se preferencialmente para a nova população aquelas cujo perímetro do cuboide têm maior valor (i.e. estão mais isoladas) (Coello et al., 2007; Deb et al., 2002). Para uma maior compreensão do método, o pseudocódigo é apresentado em Coello et al. (2007).

## 3. FRAMEWORK DE IDENTIFICAÇÃO DE SISTEMAS E CONTROLE FUZZY COM ABORDAGEM HÍBRIDA

A presente seção divide-se em: Seção 3.1, onde os parâmetros da OMO dos hiperparâmetros da ESN utilizada para a identificação do trocador de calor são apresentados, e Seção 3.2, em que o controle *fuzzy* orientado ao modelo extraído é introduzido.

### 3.1 Identificação de Sistemas Através da Otimização dos Hiperparâmetros de uma *Echo State Networks*

Para a OMO do desempenho e da complexidade da ESN, considerou-se o vetor solução composto de seis variáveis

de decisão, cada uma definindo um hiperparâmetro da ESN. A ordem de representatividade dos hiperparâmetros da ESN no vetor solução, tais como seus limites de variação são: i)  $N$ , [40, 250]; ii)  $\rho_W$ , [0, 10; 0, 99]; iii)  $sin$ , [0, 0001; 1, 0000]; iv)  $s_{back}$ , [0; 1]; v)  $\alpha$ , [0, 1; 1, 0] vi)  $c_W$ , [0, 1; 1, 0]. Considerou-se uma única rodada para a OMO dos hiperparâmetros da ESN, contando com uma população de 50 indivíduos, número máximo de 50.000 avaliações e probabilidades de *crossover* e mutação de 0,9 e 1/30, respectivamente, ambas seguindo indicação do Deb (Deb et al., 2002). O número limitado de rodadas, avaliações e de redes consideradas para a avaliação dos hiperparâmetros deveu-se à baixa infraestrutura computacional.

Cada conjunto de hiperparâmetros gerado define cinco redes que simulam o problema e avaliam desempenho e complexidade por meio das métricas i) RMSE  $f_1(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ ; e ii) número de neurônios no reservatório dinâmico  $f_2(x) = N$ , respectivamente. As séries temporais de vazão e temperatura são normalizadas entre 0 e 1 antes da divisão em conjuntos de treinamento, validação e teste. As redes são treinadas considerando-se um tempo de *washout*  $T_0 = 100$  e são validadas com o conjunto de validação. Como cada rede neural tem seus pesos inicializados aleatoriamente, as cinco redes geradas com o mesmo conjunto de hiperparâmetros são consideradas para o cálculo das métricas finais pela média aritmética, de modo a conferir uma maior validade estatística na comparação dessas soluções (Lukoševičius, 2012). Mesmo assim, o RMSE não apresenta um limite superior e inferior para qualificar uma solução, portanto também será fornecido o valor de *fit* da solução para a sua qualificação e análise final. O cálculo do *fit* é dado pela equação (4).

$$fit = 100(1 - \frac{\|\hat{T} - T\|}{\|T - \mu_T\|}) \quad (4)$$

onde  $T$  e  $\mu_T$  são o vetor de temperatura real e sua média, enquanto  $\hat{T}$  é a predição de temperatura.

### 3.2 Controle Fuzzy Orientado a um Modelo Preditivo

Uma vez produzido o modelo de ESN por meio da OMO de seus hiperparâmetros, propõe-se o controle do sistema a partir do modelo preditivo. Para isto, considera-se um controle *fuzzy* (CF) com duas entradas, uma baseada no erro (*Erro*) e outra na variação do erro ( $\Delta$ *Erro*) (Driankov et al., 1993). Conforme ilustrado na Figura 3, a saída do sistema  $T(t)$  (i.e. a temperatura do líquido) e a referência  $R(t)$  formam um erro através da formulação presente na equação (5). Este erro é derivado, formando  $\Delta E(t)$ , compondo assim as entradas do CF.




Figura 3. Representação esquemática da malha de controle do trocador de calor.

$$E(t) = R(t) - T(t) \quad (5)$$

Como a série temporal apresentava máximo e mínimo de 101,44 °C e 92,82 °C, respectivamente, definiu-se um universo de entrada de [-11;11] para ambas as entradas, de forma a dar conta da amplitude máxima de 8,62 °C. Para as duas entradas *Erro* e  $\Delta$ *Erro* foram definidos cinco conjuntos *fuzzy* – NM, NS, ZO, PS e PM – com funções de pertinência triangulares uniforme e simetricamente distribuídas no universo. Considerando que a saída do CF é a vazão de entrada do líquido no trocador de calor e que os valores de máximo e mínimo da série de vazão são 0,1001  $m^3/s$  e 0,7  $m^3/s$ , foram definidos sete conjuntos *fuzzy* – NB, NM, NS, ZO, PS, PM e PB –, também com funções de pertinência triangulares uniforme e simetricamente distribuídas no universo [0,1001;0,7]. Todos os conjuntos estão expostos na Tabela 1.

Tabela 1. Conjuntos de entrada e saída do controle *fuzzy* gerado.

<i>Erro</i>		
Conjuntos	Função	Pontos
NM	Trapezoidal	[-12 -11 -1,2 -0,4]
NS	Triangular	[-1,2 -0,02 0]
ZO	Triangular	[-0,02 0 0,02]
PS	Triangular	[0 0,02 0,6]
PM	Trapezoidal	[0,02 0,6 11 12]
$\Delta$ <i>Erro</i>		
Conjuntos	Função	Pontos
NM	Trapezoidal	[-12 -11 -3 -0,8]
NS	Triangular	[-3 -0,8 0]
ZO	Triangular	[-0,8 0 0,8]
PS	Triangular	[0 0,8 3]
PM	Trapezoidal	[0,8 3 11 12]
Vazão		
Conjuntos	Função	Pontos
NB	Triangular	[0 0,1001 0,2002]
NM	Triangular	[0,1001 0,2002 0,3002]
NS	Triangular	[0,2002 0,3002 0,4001]
ZO	Triangular	[0,3002 0,4001 0,5]
PS	Triangular	[0,4001 0,5 0,6]
PM	Triangular	[0,5 0,6 0,7]
PB	Triangular	[0,6 0,7 0,8]

As regras do CF proposto foram baseadas nas fornecidas em Driankov et al. (1993) e são apresentadas na Figura 4.

e\Δe	NM	NS	ZO	PS	PM
NM	PB	PB	PM	PS	ZO
NS	PB	PM	PS	ZO	NS
ZO	PM	PS	ZO	NS	NM
PS	PS	ZO	NS	NM	NB
PM	ZO	NS	NM	NB	NB

Figura 4. Regras de inferência para o controlador *fuzzy*.

Definidas as regras e os conjuntos *fuzzy*, a estrutura do controlador (sistema de inferência *fuzzy*) consiste no seguinte: i) *fuzzyficação*, realizada pela identificação dos graus de pertinência das entradas *Erro* e  $\Delta$ *Erro* aos conjuntos de entrada na Tabela 1; ii) inferência, que considera as regras mostradas na Figura 4 e os operadores de interseção, implicação e agregação: mínimo, máximo e máximo, respectivamente; e iii) *defuzzyficação*, aqui realizada pelo método do centróide. Percorridas essas etapas, obtém-se então a vazão de entrada para o modelo

*black-box* do trocador de calor (i.e. a ESN obtida na fase de identificação do sistemas). A partir da vazão de entrada, o modelo fará a predição da temperatura de saída  $T(t + 1)$ , fechando assim a malha de controle.

#### 4. RESULTADOS

Estão organizados na presente seção os resultados do estudo, dando a Seção 4.1 enfoque àqueles obtidos na extração do modelo *black-box* e na OMO de seus hiperparâmetros, de acordo com a abordagem multiobjetivo descrita na Seção 3.1, enquanto a Seção 4.2 trata dos resultados produzidos pelo CF aplicado ao modelo preditivo gerado.

##### 4.1 Otimização dos Hiperparâmetros da ESN

Ao final do processo de otimização, foram obtidas 50 soluções distintas, sendo 6 delas não dominadas, conforme mostra a Figura 5. Dentre as soluções obtidas, selecionou-se aquela marcada em preto, pois apresenta um número muito menor de neurônios no reservatório dinâmico, e um desempenho similar, de acordo com o RMSE, quando comparada à solução imediatamente anterior a ela, configurando assim uma boa relação de troca entre os objetivos. Os hiperparâmetros da solução selecionada e os valores obtidos nas suas avaliações estão expostos na Tabela 2, acima da melhor solução obtida para o mesmo problema em Paiva (2018). Por fim, utilizou-se a ESN que apresentou o menor RMSE na validação para realizar a predição do conjunto de teste, gerando-se assim a Figura 6.

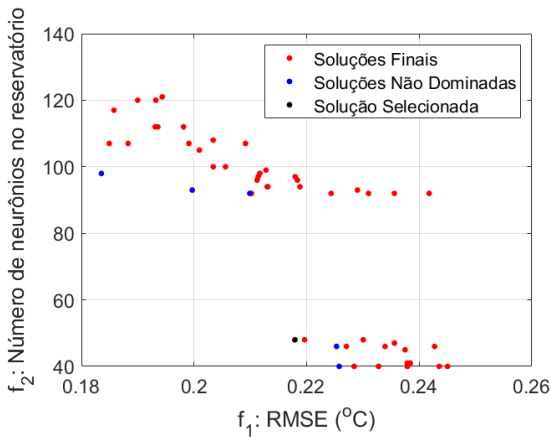


Figura 5. Frente de Pareto final com solução selecionada.

Tabela 2. Hiperparâmetros e avaliação da solução selecionada e da melhor solução encontrada em Paiva (2018).

$N$	Hiperparâmetros					Avaliação	
	$\rho_W$	$s_{in}$	$s_{back}$	$\alpha$	$c_W$	$f_1$	$f_2$
48	0,6032	0,4166	0,1090	0,8102	0,5136	0,2179	48
264	0,3595	0,2985	0,1755	0,6504	0,3470	0,1116	264

A análise visual da Figura 6 revela que a ESN selecionada generaliza bem em relação ao conjunto de teste, com exceção dos picos e vales da série, o que resultou em um RMSE de 0,2661 e um *fit* de 83,67 para o conjunto de teste, sendo considerada um modelo válido. Da Tabela 2 pode-se ver que a melhor solução encontrada em Paiva (2018) apresenta RMSE 49% inferior e complexidade

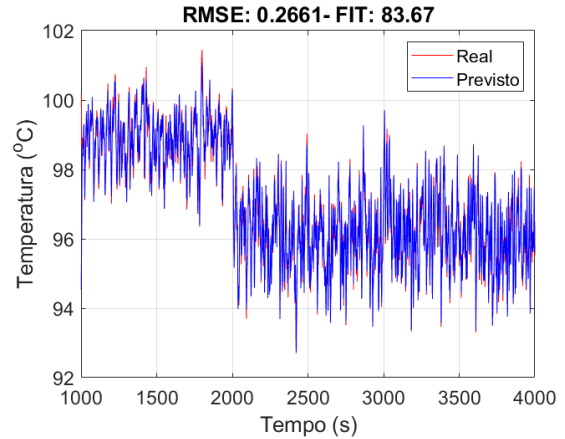


Figura 6. Predição da ESN selecionada ( $N = 48$ ) considerando dados de teste.

$(264 - 48)/48 = 450\%$  superior ao modelo encontrado no presente trabalho. Portanto, o modelo obtido aqui se destaca por obter um desempenho satisfatório ( $f_1 = 0,2179$ , melhor que o apresentado na Figura 6), mas com uma redução de complexidade significativa.

##### 4.2 Controle Fuzzy

Selecionados os hiperparâmetros da ESN de forma a haver um compromisso entre complexidade e desempenho (Tabela 2), o próximo passo foi o controle do sistema a partir do modelo preditivo.

Considerando o sinal de referência ilustrado na Figura 7, o CF inicial foi simulado com o mesmo tempo de amostragem dos dados de treinamento da rede (1s). Assim, seus conjuntos foram iterativa e manualmente alterados de modo a oferecer o melhor controle da variável temperatura de saída do líquido. Para comparação dos resultados, considerou-se a soma dos erros ao quadrado. Vale notar que os 100 primeiros dados da simulação foram descartados para o cálculo do erro, pois o vetor de vazões de entrada do modelo preditivo ainda estava em construção.

O melhor CF apresenta: i) concentração dos conjuntos de entrada próximo ao erro e variação de erro nulo, de modo a conferir maior precisão nessa região de controle; ii) perda da simetria dos conjuntos referentes à entrada *Erro*, por apresentar perfis diferentes de aquecimento e resfriamento do líquido considerado para a troca de calor.

A partir da análise da Figura 7, conclui-se que, mesmo com a concentração de conjuntos próximo ao erro e derivada do erro zero (ZO), o controle não foi capaz de eliminar o erro no regime permanente, apesar de este ser menor que  $0,1\text{ }^\circ\text{C}$ . No entanto, considera-se que o CF gerado tem um bom comportamento já que foi projetado para uma variação máxima de  $8,7\text{ }^\circ\text{C}$  e, mesmo considerando uma variação de 46% desse intervalo de temperatura (i.e.  $4\text{ }^\circ\text{C}$ ), o CF foi capaz de atingir o patamar de temperatura em menos de 10 s, com um erro em regime permanente baixo.

#### 5. CONCLUSÃO

A OMO permite o ajuste dos hiperparâmetros da ESN de modo a se obter um desempenho viável com modelos de




Figura 7. Saída do modelo de predição controlado e sinal de referência.

menor complexidade. No entanto, a métrica de complexidade a ser minimizada era também um hiperparâmetro do modelo, fazendo com que o NSGA-II tendesse a explorar soluções na “região de menor  $N$ ” do espaço de busca. Como trabalhos futuros, sugere-se i) o uso de outra métrica de complexidade, e.g. amplitude dos pesos; ii) o uso de um algoritmo de otimização capaz de trazer a busca novamente para a “regiões de maior  $N$ ” do espaço de busca, como, por exemplo, o OBLIMSSA com estratégia de *jumping rate* proposto em Domingues et al. (2019); iii) considerar mais rodadas de otimização, épocas e redes neurais para o cálculo da métrica de desempenho e iv) a comparação das ESN com outros modelos tradicionais como NARX e NARMAX.

Para o CF, apesar de existir um erro em regime permanente diferente de zero, o resultado obtido confirma a sua capacidade de controlar o sistema não-linear de troca de calor. Porém, apesar da facilidade de implementação do CF frente a outros métodos de controle não linear, ainda há grande dificuldade em definir os limites dos conjuntos de entrada e saída, sendo portanto recomendável para trabalhos futuros o uso de algoritmos evolucionários para o ajuste das funções de pertinência.

## REFERÊNCIAS

Billings, S.A. (2013). *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. John Wiley & Sons, 1st edition.

Bittanti, S. and Piroddi, L. (1997). Nonlinear identification and control of a heat exchanger: A neural network approach. *Journal of the Franklin Institute*, 334, 135–153.

Coello, C.A.C., Lamont, G.B., Van Veldhuizen, D.A., et al. (2007). *Evolutionary algorithms for solving multi-objective problems*, volume 5. Springer US, New York, NY, USA, 2nd edition.

Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303–314.

Deb, K., Pratap, A., Agarwal, S., and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE transactions on evolutionary computation*, 6(2), 182–197.

Domingues, P.H.L.S.P., Freire, R.Z., Coelho, L.d.S., and Ayala, H.V.H. (2019). Bio-inspired multiobjective tuning of pid-controlled antilock braking systems. In *2019 IEEE Congress on Evolutionary Computation (CEC)*, 888–895. IEEE, Wellington, NZ.

Driankov, D., Hellendoorn, H., and Reinfrank, M. (1993). *An introduction to fuzzy control*. Springer Science & Business Media.

Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O’Reilly Media, 2nd edition.

Goldberg, D.E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1st edition.

Haykin, S. (2010). *Neural Networks and Learning Machines, 3/E*. Pearson Education India, 3rd edition.

Ibarra, L. and Webb, C. (2016). Advantages of fuzzy control while dealing with complex/unknown model dynamics: a quadcopter example. In *Proceedings of New Applications of Artificial Intelligence*, 93.

Jaeger, H. (2001). 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*, 148(34), 13.

Lukoševičius, M. (2012). A practical guide to applying echo state networks. In *Neural networks: Tricks of the trade*, 659–686. Springer.

Moor, D. (2018). Daisy: Database for the identification of systems. department of electrical engineering, esat/stadius, ku leuven, belgium. URL <http://homes.esat.kuleuven.be/~smc/daisy/>.

Paiva, P.R.M. (2018). Modelos neuroevolucionários com echo state networks aplicados a identificação de sistemas.

Peralez, J., Tona, P., Lepreux, O., Sciarretta, A., Voise, L., Dufour, P., and Nadri, M. (2013). Improving the control performance of an organic rankine cycle system for waste heat recovery from a heavy-duty diesel engine using a model-based approach. In *52nd IEEE conference on decision and control*, 6830–6836. IEEE.

Schrauwen, B., Verstraeten, D., and Van Campenhout, J. (2007). An overview of reservoir computing: theory, applications and implementations. In *Proceedings of the 15th european symposium on artificial neural networks*. p. 471-482 2007, 471–482.

Xu, B., Rathod, D., Yebi, A., Filipi, Z., Onori, S., and Hoffman, M. (2019). A comprehensive review of organic rankine cycle waste heat recovery systems in heavy-duty diesel engine applications. *Renewable and Sustainable Energy Reviews*, 107, 145–170.

Yao, X., Wang, Z., and Zhang, H. (2018). Identification method for a class of periodic discrete-time dynamic nonlinear systems based on sinusoidal esn. *Neurocomputing*, 275, 1511–1521.

Yebi, A., Xu, B., Liu, X., Shutty, J., Ansel, P., Filipi, Z., Onori, S., and Hoffman, M. (2017). Estimation and predictive control of a parallel evaporator diesel engine waste heat recovery system. *IEEE Transactions on Control Systems Technology*, 27(1), 282–295.