

Uso de Reservoir Computing para classificação de eventos de rampa e previsão de geração de potência em parques eólicos

Tatyana M. P. Santos, Mêuser J. S. Valença
Escola Politécnica da Universidade de Pernambuco, POLI-UPE
Recife, Brasil
{tmpts, meuser}@ecomppoli.br

Abstract—The increasing use of wind power as source of electricity motivates a continuous improvement of the accuracy of wind power forecasts. There is a considerable value in optimizing forecasts systems to provide the best performance in an environment where the wind power production increases and/or decreases by a large amount over a short period of time. This paper presents a method that uses Reservoir Computing to forecast variations in energy production in wind farms, or ramp events. This method is compared with two other approaches: one that uses a MLP network and the other is based in persistence. The tests were performed and the results are given for a real case.

Keywords—wind power forecast; reservoir computing; ramp events; phase errors.

INTRODUÇÃO

Nos últimos anos, com a expansão em grande escala de parques eólicos, o percentual de energia obtida a partir de fontes eólicas está aumentando rapidamente. Assim, a demanda por uma energia eólica mais confiável está impulsionando a necessidade de detecção e previsão de eventos de rampa [1].

Existem modelos de previsão de energia eólica que se baseiam nas características físicas, do tempo, do terreno, sendo assim dependentes de aspectos físicos. Porém, os últimos trabalhos de pesquisa em previsão de potência de vento têm se concentrado mais na associação entre a incerteza e estas previsões mais pontuais, utilizando históricos de medições e algoritmos de aprendizado de máquina para induzir um modelo preditivo [2, 3].

Zheng e Kusiak [4] utilizaram dados históricos coletados pelo controle de supervisão e aquisição de dados do sistema (SCADA - *supervisory control and data acquisition*) como entrada para vários modelos regressivos para prever as taxas de rampa, Potter e Negnevitsky [5] aplicaram uma abordagem de inferência neuro-fuzzy-adaptativa para previsão de curto prazo de velocidade e direção do vento, Lange e Focken [6] apresentaram vários modelos de previsão de curto prazo de energia eólica, incluindo modelos com base física, fuzzy, e neuro-fuzzy. Utilizando-se de dados meteorológicos, Barbounis et al. [7] construíram um modelo utilizando uma rede neural recorrente local para previsão de longo prazo de velocidade do vento e energia gerada.

Este artigo também se concentra na previsão de potência gerada em parques eólicos, uma série muito dinâmica, predisposta a muitas variações. Esta série oscila muito em pequenos períodos de tempo, uma vez que sofre diversas influências de fatores físicos e meteorológicos, o que demanda a utilização de uma técnica que lide muito bem com esta volatilidade. Se corretamente aplicados, estes trabalhos têm muito a agregar na geração de energia eólica, aumentando significativamente o valor desta modalidade na nossa matriz energética.

Hoje, uma das maiores dificuldades encontradas, quando se trata da precisão da previsão da energia eólica, é fornecer uma previsão capaz de lidar com situações extremas, situações essas que ainda dependem muito das atividades dos usuários finais, que precisam desenvolver procedimentos que satisfaçam a demanda de energia elétrica, bem como maximizar os benefícios econômicos e ambientais. Estes eventos extremos estão associados a grandes desvios de geração de energia em relação ao que era esperado. A gravidade destes eventos depende da rapidez com que acontecem e do momento em que ocorrem, pois a demanda de energia elétrica também é altamente incerta. Quanto mais cedo esses eventos são previstos, mais eficazes são os procedimentos. [2,3].

Uma solução a ser considerada é tentar determinar previamente, e com a melhor precisão possível, o momento, a amplitude e a largura das variações da potência gerada e neste artigo, nós tentamos aperfeiçoar este tipo de solução. Ao visualizar gráficos de resultados dos trabalhos de pesquisa realizados neste ramo, é possível visualizar as diferenças entre os momentos de pico, crescimento, e decaimento da potência observada em relação à prevista. No contexto da previsão de energia eólica, estas observações representam uma situação chamada de erro de fase, ou seja, um erro no *timing* de uma rampa. Este tipo de problema está incluso em proposta de aperfeiçoamento em trabalhos futuros.

Neste artigo, primeiramente, na seção 2, trataremos do modelo utilizado no nosso trabalho de previsão, baseado em *Reservoir Computing*, uma abordagem de rede neural recorrente, falando um pouco de como foi aplicada e por que foi escolhida. Em seguida, na seção 3, será explicado um pouco sobre o efeito rampa, trazendo o conceito e determinando os parâmetros considerados neste artigo. Na seção seguinte, temos

os resultados dos experimentos, onde foram comparados os *improvements* em relação aos resultados provenientes de um modelo utilizando uma MLP e um modelo de persistência, em seguida, consequentes conclusões.

RESERVOIR COMPUTING

Existem certas situações complexas e problemas importantes que fazem parte da nossa realidade diária. Estes fatos já impulsionaram e continuam impulsionando pesquisas que visam trazer soluções computacionais para o que não pôde ser resolvido de forma mais trivial. Muitos problemas desafiadores e interessantes na engenharia não possuem solução direta utilizando-se de métodos heurísticos ou algoritmos explicitamente programados. Estes problemas são os principais candidatos para a aplicação de métodos de aprendizagem de máquina [8]. Estes métodos compartilham a propriedade comum de aprender através de exemplos e poder generalizá-los de uma forma "inteligente" a novas entradas ainda não vistas.

Muitas técnicas de aprendizagem de máquina existem, e uma grande subclasse é formada pelas Redes Neurais, modelos conexionistas muito abstratos da forma como o cérebro faz computação. Eles consistem em redes de nós computacionais simples e não lineares que comunicam valores através de conexões ponderadas, ou seja, que possuem seus respectivos pesos. Pela formação dos valores destes pesos com base em exemplos e treinamento, o comportamento desejado da rede é atingido. Se a rede tem uma estrutura recorrente, isto é, com loops de realimentação, então ela terá uma memória de entradas passadas, o que lhe permite fazer o processamento de sinais temporais tornando-as métodos computacionais não lineares poderosos [8].

Estas redes neurais recorrentes são, porém, notoriamente difíceis de treinar. Um novo paradigma de aprendizagem chamado *Reservoir Computing* foi introduzido, permitindo o uso de redes neurais recorrentes, aliviando a fase demorada e difícil de treinamento. A mesma ideia básica foi introduzida de forma independente nas *Echo State Networks* e *Liquid State Machines*. Em ambos os casos, a arquitetura de uma rede consiste em uma rede recorrente de neurônios chamada reservatório (do francês *Reservoir*), o qual é construído de forma aleatória e não é treinado inicialmente, e uma camada de saída linear separada, que pode ser treina com métodos simples *one-shot* [8], ou seja, não requerem grandes conjuntos de dados ou várias rodadas de treinamento (figura 1). Desde sua introdução, esta abordagem tem atraído muita atenção na comunidade de redes neurais, devido à combinação da simplicidade de uso e de seu bom desempenho em uma variedade de tarefas de *benchmark* difíceis [8].

Neste artigo, o *Reservoir Computing* será utilizado para previsão e para classificação dos eventos rampa, que podem ser entendidos, de maneira geral, como uma variação na potência nominal superior a um limiar que perdura por certo período de tempo. Uma definição mais concreta sobre estes eventos, compatível com os estudos de caso trazidos neste artigo, é apresentada na seção seguinte.

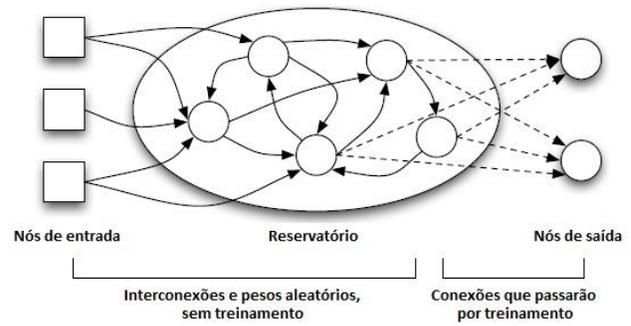


Fig. 1. Representação esquemática de um sistema de *Reservoir Computing*. As conexões fixas e formadas aleatoriamente são indicadas com uma linha sólida, as conexões treinadas são indicadas com uma linha tracejada.

EVENTOS RAMPA NA GERAÇÃO DE ENERGIA EÓLICA

Recentemente a indústria de energia eólica começou a avaliar a natureza dos eventos rampa. Ainda não existe um limiar de aceitação universal para detectá-los [9], o conceito mais comumente utilizado é o que define o evento rampa como uma variação que excede um percentual mínimo da potência nominal (V_{min}) em um parque eólico dentro de um período de tempo menor ou igual a uma duração máxima (T_{max}) [2 e 9], ou seja, quando há uma alteração na potência de saída que tenha uma amplitude suficientemente grande para um período de tempo relativamente curto [3]. É difícil encontrar um consenso entre os valores de V_{min} e T_{max} , pois normalmente dependerão da situação geográfica, clima e complexidade do terreno e acabam sendo fixados "arbitrariamente" pelo modelador da solução [2].

Neste trabalho, o comportamento das bases de dados refletiu bastante o que foi dito acima, os valores de V_{min} e T_{max} variam sensivelmente de acordo com as condições locais do parque eólico. Para fazer a definição dos parâmetros e continuar favorecendo o comportamento individual da geração em cada parque eólico, optamos por não fixar um valor universal para V_{min} e T_{max} , mas fazê-lo de acordo com a quantidade de eventos observada de acordo com a variação destes parâmetros. A rampa deve ser um evento esparsos, sem se repetir muitas vezes, de forma que o evento não fique muito generalizado, então, ao trabalhar os dados, admitimos que a quantidade de valores encontrados acima do limiar V_{min} deveria ser cerca de 10% do total. Para encontrar essas quantidades de valores observadas em cada limiar, fizemos o seguinte processo:

- 1º) Aplicar filtros que tornem possível visualizar os percentuais de variação da série;
- 2º) Realizar a contagem das ocorrências para cada percentual de variação;
- 3º) Para cada percentual de variação, verificar qual o percentual que a quantidade de ocorrências representa em relação ao todo.

Para o primeiro passo do processo, nos baseamos numa abordagem que não trabalha diretamente com o sinal da potência gerada no parque, mas transforma o sinal em uma representação mais adequada. Esta estratégia é utilizada em

Bossavy et al. (2010), por exemplo, e consiste em considerar as diferenças na amplitude da potência gerada. Neste procedimento, considere $(p_t)t$ a série temporal da potência de vento e $(p_t^f)t$ o sinal filtrado associado, obtido através da seguinte fórmula:

$$p_t^f = \text{média} \{ p_{t+h} - p_{t+h-n_{am}}; h = 1, \dots, n_{am} \} \quad (1)$$

Nesta fórmula, o n_{am} vem da quantidade de diferenças de medidas de potência a serem consideradas na média (*number of averaged differences of measures*). O sinal filtrado $(p_t^f)t$ mede as variações da série de potência de vento $(p_t)t$. O evento de rampa então corresponderá a um intervalo de tempo onde o valor absoluto do sinal filtrado y excederá um limiar $l > 0$. O tempo da rampa é o ponto onde o sinal filtrado $(p_t^f)t$ atinge um máximo local. A figura 3 abaixo demonstra parte das análises feitas até que pudéssemos escolher o n_{am} adequado. Trabalhamos com séries temporais de geração de potência de três parques eólicos no Brasil, aqui denominados Parque A, Parque B e Parque C. A figura abaixo foi extraída da série referente ao Parque A.

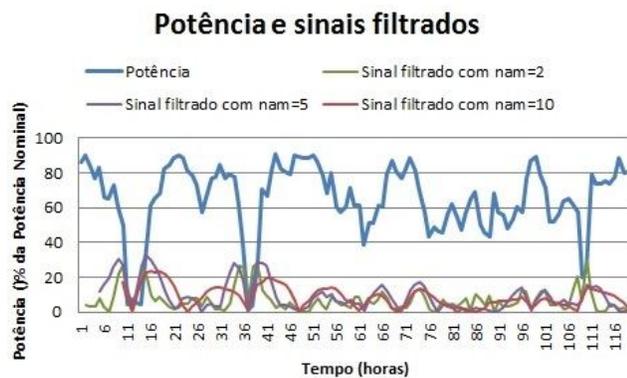


Fig. 3. Parte da série de geração de potência no Parque A $(p_t)t$ e valores absolutos do sinal filtrado $(p_t^f)t$ com os parâmetros $n_{am}=2$, $n_{am}=5$ e $n_{am}=10$. As rampas coincidem com os pontos máximos locais do sinal filtrado. Considerando o limiar de 20% da potência nominal, podemos observar 6 eventos de rampa com $n_{am}=2$ e 4 eventos com $n_{am}=5$ acima. Com $n_{am}=5$, perdemos a identificação das rampas observadas em $t=108$ e 110 em relação a $n_{am}=2$, isto acontece porque valores menores de n_{am} fazem o sinal filtrado ficar mais sensível a variações em períodos menores de tempo. Para a linha de $n_{am}=10$, observa-se que valores maiores de n_{am} sempre resultarão em um sinal filtrado cada vez menos sensível às variações da potência gerada.

Com as três séries de potência utilizadas como estudo de caso neste artigo (Parque A, Parque B e Parque C), utilizando-se da definição que fixamos acima, o valor de n_{am} permaneceu 5 para os três casos e os limiares variaram, sendo 15% para o Parque A, 20% para o Parque B e 40% para o Parque C. Encontramos 890 valores excedendo o limiar de 15% durante um período de 5855 horas, com medição ocorrendo de 30 em 30 minutos no Parque A, 1236 valores excedendo o limiar de 20% durante um período de 8784 horas (um ano) com medição ocorrendo de 30 em 30 minutos no Parque B e 1243 valores excedendo o limiar de 40% durante um período de 8784 (um ano) com medição ocorrendo de 30 em 30 minutos no Parque C. Transformamos as séries em horários antes de definir os n_{am} s, então $n_{am}=5$ quer dizer 5h e $n_{am}=2$ quer dizer 2h, ou

seja, para o Parque A, por exemplo, a definição da rampa fica como sendo uma variação de 15% no período de 5h ou menos.

Através de testes, observamos que teríamos mais exemplos de rampas optando por utilizar $n_{am}=5$ ao invés de $n_{am}=2$ e escolhendo um limiar abaixo de 15%, 10% por exemplo, poderíamos observar mais rampas, porém, como já foi falado anteriormente, aumentaríamos muito a sensibilidade do filtro e a geração toda estaria repleta de rampas, generalizando demais o evento.

EXPERIMENTOS E COMPARAÇÕES DE RESULTADOS

Os experimentos foram realizados do ponto de vista de classificação e previsão. Além do *Reservoir Computing*, foram utilizados um MLP e um modelo de persistência para comparação de resultados.

A. Configurações utilizadas

Para as redes neurais, seguem abaixo os valores utilizados em suas configurações:

1) *Classificação*: Tanto para o *Reservoir* quanto para a MLP, foram utilizados 48 neurônios de entrada e 38 neurônios de saída. As 48 entradas dizem respeito a um dia inteiro de medição, ocorrendo de 30 em 30 minutos, já os 38 neurônios de saída correspondem a janelas de 5 horas percorrendo o dia inteiro, de 30 em 30 minutos, já que esse foi o período máximo definido para detecção da variação a ser caracterizada ou não como evento rampa. Para os neurônios da camada escondida, foram utilizados 15 para o *Reservoir Computing* e 5 para a MLP. Para o *Reservoir Computing*, chegamos a este número de neurônios na camada escondida realizando testes entre configurações possíveis, comparando o percentual de classificações corretas e verificando se a escolha tinha capacidade de generalização para uma boa classificação de todos os parques eólicos em estudo, desta forma, também selecionamos a taxa de interconectividade dos neurônios no reservatório, 82%, e a quantidade de ciclos de aquecimento, 5. Para a MLP, o número de neurônios na camada escondida foi encontrado juntamente com os valores da taxa de aprendizado (0,2) e momento (0,8), após realização de testes permutando entre configurações possíveis e verificando o impacto no resultado final, sendo selecionada a configuração que deu origem à melhor taxa de classificações corretas.

2) *Previsão*: Assim como para a classificação, tanto para o *Reservoir* quanto para a MLP, foram utilizados 48 neurônios de entrada pelo mesmo motivo citado anteriormente, já a quantidade de neurônios de saída mudou para 48. Os 48 neurônios de saída dizem respeito a um dia inteiro de previsão à frente, também de 30 em 30 minutos. Para os neurônios da camada escondida, foram utilizados 150 para o *Reservoir Computing* e 75 para a MLP. Assim como foi dito para os casos de classificação, chegamos a estes valores realizando testes entre configurações possíveis, porém realizando as comparações a partir de outras métricas, são elas: o Erro Médio Quadrático (EMQ) e o Erro Médio Absoluto Normalizado (EMAN), desta forma também selecionamos a taxa de interconectividade dos neurônios no reservatório, 50%, e a quantidade de ciclos de aquecimento, 5.

B. Comparações de resultados

As métricas utilizadas para as comparações entre os resultados, conforme mencionado acima, foram: o Erro Médio Quadrático (EMQ) (2) e o Erro Médio Absoluto Normalizado (EMAN) (3). Seguem as fórmulas:

$$EMQ = \sqrt{\frac{\sum(\text{Valor observado} - \text{Valor calculado})^2}{N}} \quad (2)$$

$$EMAN = \frac{EMA}{\text{Potência instalada da usina}} \quad (3)$$

$$EMA = \frac{\sum|\text{Valor observado} - \text{Valor calculado}|}{N} \quad (4)$$

Sendo N é a quantidade de valores no conjunto de verificação.

Para o cálculo do EMAN, pode-se optar por utilizar a potência instalada do parque eólico como denominador ou a média entre as potências registradas, ambas as abordagens possuem seus pontos positivos e negativos, para a potência instalada corre-se o risco de não levar em conta um valor realista, pois é comum que as usinas não operem com todos os seus aerogeradores ligados, já para a potência média, corre-se o risco de utilizar um valor muito baixo, pois a série pode conter muitos valores negativos (considerados como zero), referentes a momentos que a usina está reabsorvendo potência, e a média cairá. No nosso caso, utilizamos a potência instalada justamente pelo fato de as séries utilizadas como estudo de caso possuírem momentos de reabsorção da usina.

Reservoir Computing

Com *Reservoir Computing* conseguimos chegar a uma taxa de acerto de 100% das classificações dos eventos rampa no Parque A e no Parque C, no Parque B conseguimos chegar a uma taxa de 94,4% de acerto. Apesar de citar uma melhor configuração acima, com 15 neurônios na camada escondida, 82% de interconectividade entre os neurônios da camada escondida e 5 ciclos de aquecimento, conseguimos esta mesma taxa de 100% com várias outras configurações para os Parques A e C, mas a configuração citada acima foi escolhida por ser um modelo que também trouxe o melhor resultado para o Parque B e por ser mais parcimonioso, ou seja, oferece resultado satisfatório com menos variáveis e/ou menor tempo de processamento. Nos casos dos Parques A e C, a taxa de acerto só reduziu para menos de 100% quando a quantidade de neurônios na camada escondida chegou a 100 no caso do Parque A e 50 para o Parque C e com uma taxa de interconectividade de aproximadamente 85% para o Parque A e 80% para o Parque C. Os testes foram realizados incrementando-se sempre a quantidade de neurônios na camada escondida e a taxa de interconectividade entre os neurônios da camada escondida, de 50% até 100%, em relação à quantidade de ciclos de aquecimento, não se notou diferença após 5 ciclos, então fixamos este valor nas permutações entre configurações.

TABELA I. RESULTADOS DOS TESTES PARA DEFINIÇÃO DE MELHOR CONFIGURAÇÃO PARA CLASSIFICAÇÃO COM MODELO DE ARQUITETURA RESERVOIR COMPUTING

	Neurônios camada escondida	Taxa de interconectividade	Taxa de acerto
Parque A	15	82%	100%
Parque B			94,44%
Parque C			100%

Para a previsão, a melhor configuração encontrada foi de 75 neurônios na camada escondida e taxa de interconectividade de 50%, resultando em um EMAN de 13,22%, que pode ser interpretado diretamente: o modelo apresentou um erro médio de 13,22% da potência instalada do parque. Uma taxa muito próxima também foi encontrada utilizando-se de 150 neurônios na camada escondida, com a mesma taxa de interconectividade. Pela preferência por um modelo mais parcimonioso, vamos adotar a configuração de 75 neurônios na camada escondida mais a frente como melhor configuração para realização dos testes. Quanto aos ciclos de aquecimento, assim como para a classificação, não se notou diferenças entre os resultados variando a quantidade de ciclos acima de 5, então fixamos este valor nas permutações entre configurações. A tabela abaixo mostra destacados em cinza os registros referentes aos resultados das configurações citadas, e alguns outros exemplos de resultados obtidos durante as execuções dos testes para o Parque A:

TABELA II. RESULTADOS DOS TESTES PARA DEFINIÇÃO DE MELHOR CONFIGURAÇÃO PARA PREVISÃO COM MODELO DE ARQUITETURA RESERVOIR COMPUTING

Neurônios camada escondida	Taxa de interconectividade	EMAN (%)	EMQ
30	50%	13,45	173,8928
30	85%	13,47	174,6610
30	100%	13,52	175,0369
50	50%	13,33	171,5545
50	85%	13,41	172,5126
50	100%	13,37	172,5479
75	50%	13,22	170,1146
75	85%	13,29	171,0761
75	100%	13,30	171,6811
150	50%	13,22	170,7529
150	85%	13,33	172,1388
150	100%	13,31	172,4118

MLP

Como já citamos anteriormente, a melhor configuração para a classificação utilizando a rede MLP foi de 5 neurônios na camada escondida, taxa de aprendizado de 0,2 e momento 0,8, resultando numa taxa de acerto de 76,96%. A tabela abaixo mostra esse, destacado em cinza, e alguns outros exemplos de resultados obtidos durante as execuções de testes para o Parque A:

TABELA III. RESULTADOS DOS TESTES PARA DEFINIÇÃO DE MELHOR CONFIGURAÇÃO PARA CLASSIFICAÇÃO COM MODELO DE ARQUITETURA MLP

Taxa de aprendizado	Momento	Neurônios camada escondida	Taxa de acerto
0,2	0,8	5	76,96%
0,5	0,5	5	72,94%
0,8	0,2	5	76,23%
0,2	0,8	15	73,35%
0,5	0,5	15	73,93%
0,8	0,2	15	71,31%
0,2	0,8	30	73,12%
0,5	0,5	30	74,05%
0,8	0,2	30	72,68%

Para previsão, a melhor configuração foi de 75 neurônios na camada escondida, taxa de aprendizado de 0,8 e momento 0,2. A tabela abaixo mostra esse, destacado em cinza, e alguns outros exemplos de resultados obtidos durante as execuções dos testes:

TABELA IV. RESULTADOS DOS TESTES PARA DEFINIÇÃO DE MELHOR CONFIGURAÇÃO PARA PREVISÃO COM MODELO DE ARQUITETURA MLP

Taxa de aprendizado	Momento	Neurônios camada escondida	EMAN (%)	EMQ
0,2	0,8	15	16,60	198,5585
0,5	0,5	15	14,23	15,15271
0,8	0,2	15	14,31	154,7231
0,2	0,8	30	18,41	262,9488
0,5	0,5	30	14,25	152,6773
0,8	0,2	30	14,20	151,9171
0,2	0,8	50	19,67	308,1769
0,5	0,5	50	14,07	151,0663
0,8	0,2	50	13,84	144,4271
0,2	0,8	75	24,13	455,2665
0,5	0,5	75	14,27	152,4779
0,8	0,2	75	13,74	141,5071

Persistência

Para o modelo de persistência, consideramos que o dia seguinte terá os mesmos valores de potência registrados no dia atual. No caso de classificação, verificamos a quantidade de rampas que de fato ocorreram em um dia e comparamos com a quantidade de rampas que o modelo de persistência acerta considerando que o dia seguinte será igual ao corrente. A tabela abaixo exibe a taxa de acerto encontrada para os parques eólicos A, B e C:

TABELA V. RESULTADOS DOS CÁLCULOS DE CLASSIFICAÇÃO COM MODELO DE PERSISTÊNCIA

	Taxa de acerto
Parque A	41,87%
Parque B	43,92%
Parque C	12,87%

A tabela abaixo contém as taxas de erros encontradas com a utilização deste modelo para previsão:

TABELA VI. RESULTADOS DOS CÁLCULOS DOS ERROS DE PREVISÃO COM MODELO DE PERSISTÊNCIA

	EMA	EMAN (%)	EMQ
Parque A	9,78	20,38	195,2604
Parque B	22,83	47,56	230,8667
Parque C	7,02	14,62	540,0352

Com os três modelos testados acima, calculamos o *improvement* entre eles, baseando-se na taxa de acerto (classificação) e no Erro Médio Absoluto Normalizado (EMAN, previsão) dos melhores casos, para determinar o melhor modelo a utilizarmos nos nossos casos de estudo: classificação de eventos de rampa e previsão de potência para correção de erro de fase. A fórmula utilizada para cálculo do *improvement* segue abaixo:

$$Improvement = \frac{EMAN_{modelo1} - EMAN_{modelo2}}{EMAN_{modelo1}} * 100 \quad (5)$$

Apesar de o Erro Médio Quadrático também ter sido calculado, levamos em consideração o Erro Médio Absoluto Normalizado por ser uma métrica comumente utilizada nos trabalhos que têm como estudo de caso séries de geração de potência [10, 11, 12], inclusive proposta como padrão, pois o EMQ é mais relevante quando erros pequenos são de menor importância em comparação com erros maiores na previsão. Os resultados obtidos encontram-se na tabela abaixo:

TABELA VII. CÁLCULOS DOS IMPROVEMENTS ENTRE OS MODELOS COMPARADOS

		<i>Improvement</i>
Classificação	<i>Reservoir Computing</i> x MLP	23,04%
	<i>Reservoir Computing</i> x Persistência	58,13%
	MLP x Persistência	45,60%
Previsão	<i>Reservoir Computing</i> x MLP	3,93%
	<i>Reservoir Computing</i> x Persistência	54,16%
	MLP x Persistência	48,33%

Com as métricas em questão (EMAN e Taxa de acerto), o modelo do *Reservoir Computing* demonstrou melhores resultados em relação à MLP e ao modelo de persistência. Já entre a MLP e o modelo de persistência, a MLP demonstrou melhores resultados.

No tópico abaixo, realizamos testes estatísticos para uma apuração mais refinada sobre o modelo que apresentou o melhor desempenho para previsão, sendo possível verificar se seus resultados podem ser considerados estatisticamente

iguais, já que a taxa de *improvement* entre o modelo com arquitetura *Reservoir Computing* e o modelo com arquitetura MLP foi tão baixa.

C. Testes estatísticos

Para realização dos testes, executamos os modelos da MLP e do *Reservoir Computing* em suas melhores configurações 30 vezes, guardando os erros médios absolutos normalizados resultantes (EMANs).

Começamos utilizando o teste de *Shapiro-Wilk* com o objetivo de analisar se os dados estão normalmente distribuídos e, em caso positivo, realizamos o Teste F para verificar se a variância pode ser considerada como originada de uma mesma população. Ao passarmos por estes testes com resultados positivos, aplicamos o teste *T-Student* para dados não emparelhados. Caso as amostras não sejam consideradas normais ou não passem no Teste F, é aplicado o teste da Soma dos Postos de Wilcoxon.

Teste de Shapiro-Wilk

Admitimos a formulação das hipóteses da seguinte maneira:

Hipótese nula: A amostra provém de uma população normalmente distribuída;

Hipótese alternativa: A amostra não provém de uma população normalmente distribuída.

O nível de significância (α) do teste estabelecido foi de 0,05. Após execução do teste para cada conjunto, analisamos o p-value encontrado e comparamos com o nível de significância adotado. Caso o p-value seja menor que o nível de significância, a hipótese nula deve ser rejeitada e a amostra não deve ser considerada normalmente distribuída.

A amostra referente ao modelo da MLP sinalizou ser normalmente distribuída, enquanto a outra amostra, referente ao modelo do *Reservoir Computing*, sinalizou não ter origem em uma população normalmente distribuída.

A partir deste resultado, tornou-se desnecessária a realização do teste *T-Student*. Por causa disso, o próximo passo foi a aplicação do teste da Soma dos Postos de Wilcoxon.

Teste da Soma dos Postos de Wilcoxon

Para comparação dos resultados das previsões, as hipóteses foram definidas da seguinte maneira:

Hipótese nula: Os desempenhos das redes neurais com as arquiteturas *Reservoir Computing* e MLP são considerados estatisticamente iguais;

Hipótese alternativa: O desempenho da rede neural com a arquitetura *Reservoir Computing* é melhor do que o desempenho da rede com arquitetura MLP.

Assim como para o teste de *Shapiro-Wilk*, o resultado é admitido de acordo com o p-value, caso seja menor que o nível de significância (0,05), a hipótese nula deve ser rejeitada.

O p-value deste teste teve valor muito menor do que o nível de significância, logo, rejeitou-se a hipótese nula e concluiu-se que o uso do modelo proposto com arquitetura de

Reservoir Computing possui um melhor desempenho em relação ao modelo da MLP.

CONCLUSÕES

Propusemos um modelo que utiliza uma rede neural recorrente com método de aprendizado diferenciado, denominada *Reservoir Computing* para tentar promover melhores resultados nas classificações de eventos de rampa e em previsões de geração de potência em parques eólicos. Como modelos de referência, utilizamos uma rede neural de arquitetura MLP e um modelo de persistência.

Os resultados indicam que o modelo proposto teve melhor desempenho em relação aos modelos de referência tanto para as classificações quanto para as previsões, conseguindo um destaque maior principalmente para as classificações dos eventos de rampa.

Para as previsões, onde a taxa de *improvement* entre o modelo proposto e o modelo da rede MLP ficou mais baixa, foram realizados testes estatísticos para respaldo do resultado, que confirmou o melhor desempenho do modelo de *Reservoir Computing*.

REFERÊNCIAS

- [1] Kamath, C., "Understanding Wind Ramp Events through Analysis of Historical Data," *Proceeding of the IEEE PES Transmission and Distribution Conference and Expo*, New Orleans, USA, 2010.
- [2] Bossavy, A., Girard, R., and Kariniotakis, G., "Forecasting Uncertainty Related to Ramps of Wind Power Production," *Proceedings of the European Wind Energy Conference & Exhibition (EWEC)*, Warsaw, Poland, 2010.
- [3] Ferreira, C., Gama, J., Matias, Botterud, A., and Wang, J., "A Survey on Wind Power Ramp Forecasting", Chicago, USA, 2010
- [4] Zheng, H., and A. Kusiak, "Prediction of Wind Farm Power Ramp Rates: A Data-Mining Approach," *Journal of Solar Energy Engineering*, vol. 131, pp. 031011-1-031011-8, 2009.
- [5] Potter, C. W., and Negnevitsky, M., "Very Short-Term Wind Forecasting for Tasmanian Power Generation," *IEEE Trans. Power Syst.*, vol. 21, pp. 965-972, 2006.
- [6] Lange, M., and Focken, U., "Physical Approach to Short-Term Wind Power Prediction," *Springer-Verlag*, Berlin, p. 208, 2006.
- [7] Barbounis, T. G., Theocharis, J. B., Alexiadis, M. C., and Dokopoulos, P. S., "Long-Term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models," *IEEE Trans. Energ. Convers.*, 21(1), pp. 273-284, 2006.
- [8] Verstraeten, D., "Reservoir Computing: computation with dynamical systems," 2009.
- [9] B. Greaves, J. Collins, J. Parkes, and A. Tindal. "Temporal forecast uncertainty for ramp events". *Wind Engineering*, vol. 33, pp. 309-319, Jun. 2009.
- [10] Madsen, H., Kariniotakis, G., Nielsen, H.Aa., Nielsen, T.S., Pinson, P., "A Protocol for Standardizing the Performance Evaluation of Short - Term Wind Power Prediction Models," *CD-Proceedings of the 2004 Global Wind-power Conference*, Chicago, USA, Mar. 2004.
- [11] Martí, I., Kariniotakis, G., Pinson, P., Sanchez, I., Nielsen, T. S., Madsen, H., Giebel, G., Usaola, J., Palomares, A.M., Brownsword, R., Tambke, J., Focken, U., Lange, M., Sideratos, G., Descombes, G., "Evaluation of Advanced Wind Power Forecasting Models - Results of the Anemos Project," *Proceedings of the European Wind Energy Conference (EWEC)*, 2006.
- [12] Kariniotakis, G., Pinson, P., Siebert, N., Giebel, G., Barthelmie, R., "The state of the art in short-term prediction of wind power - from an offshore perspective," *Proceedings of 2004 SeaTechWeek*, Brest, France, Oct. 2004.