

08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

AVALIAÇÃO DE POTENCIAL EÓLICO E SOLAR COM CORRELAÇÕES DE LONGO ALCANCE EM SÉRIES TEMPORAIS EM SALVADOR

SANTOS, José Vicente Cardoso¹ - prof.vicentecardoso@gmail.com

AYLAS, Georgynio Yossimar Rosales¹ - ragy3008@gmail.com

ACIOLI, Palmira Maria de Santana¹ - palmira.engmec@gmail.com

MARINHO, Chrislaine do Bomfim¹ - chrislaine.bm@gmail.com

MOREIRA, Davidson Martins¹ - davidson.moreira@fieb.org.br

MORET, Marcelo Albano¹ - mamoret@gmail.com

¹Centro Universitário do Serviço Nacional de Aprendizagem Industrial - Centro Integrado de Manufatura e Tecnologia (Centro Universitário SENAI-CIMATEC) - Salvador, BA, Brasil.

Resumo: Este trabalho mostra a existência de correlações de longo alcance das séries históricas e temporais de velocidade do vento e radiação solar na cidade de Salvador (Bahia) provenientes de dados medidos em estações meteorológicas, além de simulações com o modelo de mesoescala WRF (Weather Research and Forecasting), através do método DFA (Detrended Fluctuation Analysis). Resultados preliminares indicam que as séries de dados locais são caracterizadas com persistência na velocidade do vento e radiação solar de forma satisfatória para a geração de energia, o que indica viabilidade da participação destas respectivas matrizes na matriz energética local.

Palavras-Chave: Fontes renováveis, DFA, Complexidade, Energia eólica. Energia solar.

1. INTRODUÇÃO

O atual cenário das demandas energéticas em todo o mundo perpassa por tentativas de proporcionar adoção de fontes alternativas de energias, visto que a proposta de substituição das fontes existentes já não é mais um consenso, pois não basta apenas pensar em substituição de fontes de energia, mas também garantir a continuidade da mesma evitando possíveis rupturas no fornecimento energético. Desta forma, a prospecção de novas fontes de energia deve ser fomentada e também devidamente valorada (Orum e Koçak, 2009; Bludszuweit e Navarro, 2011). No caso específico do Brasil, considera-se que exista um alto potencial de geração de energia nas matrizes eólica e solar, não obstante as mesmas ainda estarem em sua fase embrionária de exploração e de forma independente, demandando-se o seu uso em indexação devido as suas sazonalidades que se complementam (Brasil, 2016).

O entendimento da dinâmica das variáveis que determinam o potencial de geração de energia na matriz eólica, tal como a evolução temporal da velocidade do vento, e na matriz solar, a citar a intensidade da radiação solar e os locais de sua maior ocorrência, é um assunto de grande interesse, pois os processos de maximização deste potencial reverte-se em maior eficiência e lucratividade do processo de geração de energia. Neste sentido, merece considerar que as previsões meteorológicas, em geral, são de curto alcance temporal e acabam por não proverem cenários de longo alcance, tanto para a matriz eólica quanto para a matriz solar, em função das incompletudes específicas das variáveis principais desconhecidas para a determinação dos respectivos potenciais. Desta forma, as previsões de curto alcance acabam por ficarem sujeitas às variações específicas e locais (Jaramillo e Borja, 2004).

Por outro lado, em grande escala e em médio alcance, no que refere-se às variações de temperatura, que desdobram-se para o comportamento da velocidade do vento e para a radiação solar, uma semana mais quente é geralmente seguida de uma semana mais fria, que na realidade corresponde à média de duração dos regimes meteorológicos mais frequentes. No que refere-se aos alcances mais longos, que são governados por diferentes processos, como padrões de circulação de ventos, para o caso eólico, a posição da terra na órbita do sol, para o caso da matriz solar, ou até mesmo influências de fenômenos climáticos como o aquecimento global, o ato de definir uma correlação de longo alcance torna-se mais difícil para ambas as matrizes, eólica e solar (Kurnaz, 2004).

Desta maneira, este trabalho tem como objetivo avaliar correlações de longo alcance usando o método DFA (*Detrended Fluctuation Analysis*) (Peng et al., 1994) em séries medidas em estações meteorológicas, além de dados simulados pelo modelo WRF (*Weather Research and Forecasting*) (Skamarock et al., 2008), nas variáveis velocidade do vento e radiação solar em Salvador, Bahia, para o mês de janeiro de 2014.

2. REVISÃO DE LITERATURA

2.1 As séries temporais

As séries temporais são definidas como sendo o conjunto de dados que são coletados, geralmente, em intervalos regulares de tempo e que se diferenciam dos dados coletados aleatoriamente devido ao fato de representarem a evolução temporal da sequência da dinâmica de uma determinada variável específica e de serem coletadas em intervalos periódicos de coleta sendo que, nos casos em análise, trata-se da velocidade do vento e da radiação solar, onde se tem o ordenamento desta série de forma cronológica (Koçak, 2009).

2.2 O método DFA

A extração de informações relativas à existência de correlações de longo alcance, que pode servir para consubstanciar e projetar eventuais potenciais de geração de energia nas suas diversas matrizes, neste caso a eólica e a solar, perpassa por uma análise específica dos registros das séries temporais e da existência, ou não, de correlação de longo alcance não estacionárias nas mesmas. Para tal, pode ser utilizado o método denominado de DFA. O método foi aplicado inicialmente para a análise de DNA e sua evolução (Peng et al., 1994; Stanley et al. 1999), economia (Liu et al. 1997; Mantegna and Stanley, 2000; Costa and Vasconcelos, 2003), dinâmica cardíaca (Ivanov et al. 1996, Havlin et al. 1999), temperatura (Koscielny-Bunde et al., 1998), geologia (Malamud and Turcotte, 1999), clima (Ivanova and Auloos, 1999), estrutura de nuvens (Ivanova et al., 2000), escoamento em rios (Montanari et al., 2000), estudos de canais de íons (Siwy, 2002), transições de fase (Zebende et al. 2004),

análise de flutuação do raio-X de sistemas astrofísicos (Moret et al., 2003; Zebende et al., 2005), energia em proteínas (Figueiredo et al., 2010), manchas solares (Moret, 2014), dengue (Azevedo et al., 2016), entre outros. Além disto, observa-se de forma frequente que vários fenômenos naturais têm como propriedade comum uma dinâmica caracterizada pela existência de correlações de longo alcance, ou seja, quando a sua função de autocorrelação diminui (ou aumenta) seguindo uma lei de potência (Tsonis et al., 1999; Glahn et al., 2009).

O método DFA consiste na análise de flutuações dos dados após retirar-se a tendência da série temporal integrada, ou seja, obtêm-se uma série integrada que é dividida em intervalos independentes, conforme evidencia-se na Fig. 1, onde consideram-se os intervalos não sobrepostos nos seus tamanhos, de forma que, em cada intervalo é retirada a tendência local através de ajuste polinomial (linear, quadrático ou em outros graus de expoente) repetidas vezes, em um processo iterativo em escala através de uma lei de potência com um expoente específico, que pode ser calculado através de código fonte disponível em fórum *on-line*¹ ou deduzível algoritmicamente e implementável em *software* específico.

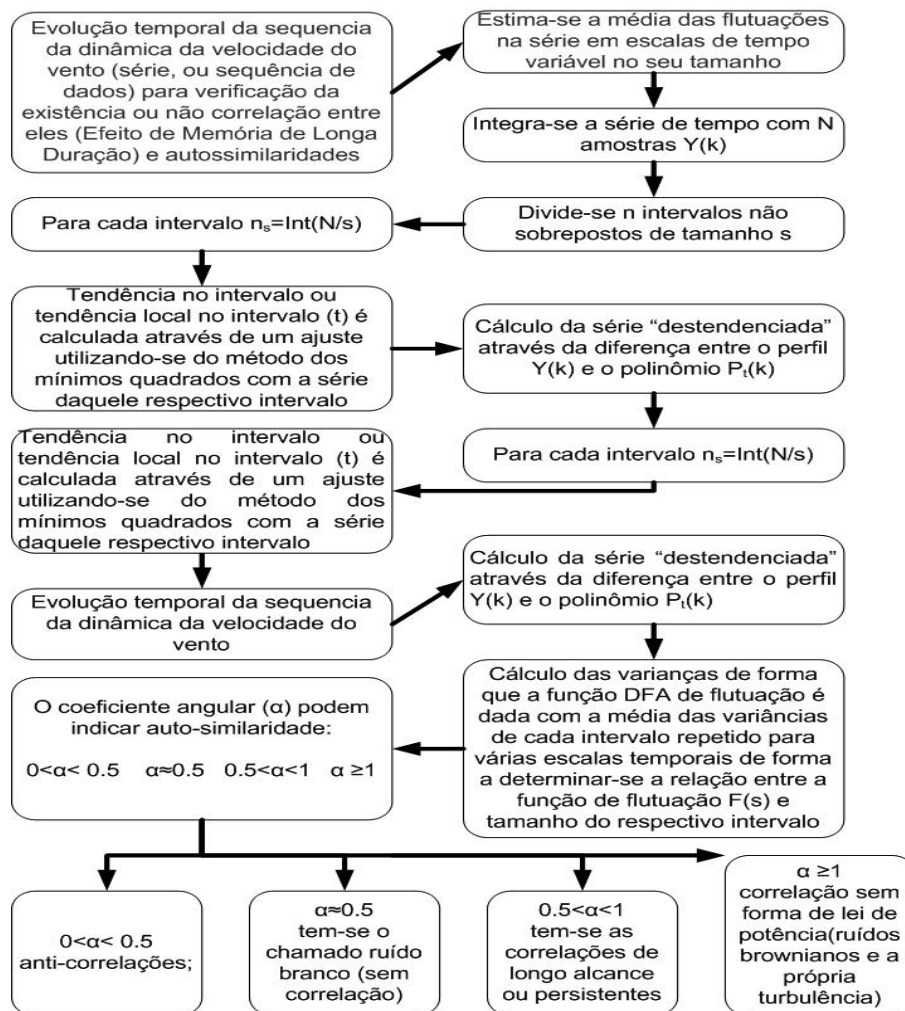


Fig. 1: Fluxograma do método DFA.

O método DFA foi proposto por Peng et al. (1994) para análise de sequências de gênicas e, a partir daí, vem sendo usada como uma técnica para quantificar correlações em séries

¹ A exemplo tem-se o dfa.c, em linguagem de programação C, disponível na página da PhysioNet (Mietus, J.; Peng, C-K.; Moody, G., 2001), ou em desenvolvimento via biblioteca de *software*, a exemplo o Matlab V.5.

temporais não estacionárias em diversas aplicações (Bunde et al., 2000; Bunde et al., 2001; Ivanov et al., 2004; Jiang et al., 2009). Trata-se de uma derivação do método denominado FA (*Fluctuation Analysis*), pois o DFA elimina a tendência da série temporal em diferentes escalas, analisando especificamente flutuações intrínsecas dos dados.

Conforme evidenciado na Fig. 1, o algoritmo para calcular o DFA integra a série de tempo a ser analisada (com N amostras) tendo considerado uma série temporal x_i ($i = 1, 2, \dots, N$) da velocidade do vento horária ou das intensidades de radiação solar registradas temporalmente, e, em ambos os casos, o primeiro passo é obter-se os valores de x_i com a relação, $x'_i = x_i - \bar{x}$, onde \bar{x} representa a média aritmética de todos os dados. O segundo passo é construir o perfil $X(i)$ como, o somatório dos valores de cada elemento da série. O perfil é então dividido em $N_s = N/s$ segmentos, não sobrepostos, de comprimento s . Se N_s não é inteiro, um segmento de comprimento menor que s permanecerá no fim da série.

Para levar em conta esta parte da série, o mesmo procedimento é repetido partindo do outro lado do registro (Kantelhardt et al., 2001). Em outras palavras, $2N_s$ são os números de segmentos e que deve ser processado durante o procedimento DFA. No terceiro passo, a tendência local é determinada usando os mínimos quadrados para cada segmento v . Então, é calculada a diferença entre a tendência local e o segmento em questão. No fim deste procedimento é obtida uma série temporal corrigida, de modo que $X_s(i) = X(i) - p_v(i)$, onde $p_v(i)$ é o ajuste polinomial para o v th segmento. Finalmente, a raiz quadrada da variância média de todos os segmentos dá a função flutuação,

$$F(s) = \left[\frac{1}{2N_s} \sum_{v=1}^{2N_s} F_s^2(v) \right]^{1/2} \quad (1)$$

Se n é o grau do ajuste polinomial tem-se que $F^{(n)}(s)$ representa a função flutuação de diferentes ordens de correção. Se a série original tem correlação de longo alcance, então $F^{(n)}(s)$ aumenta com s de acordo com a lei de potência,

$$F^{(n)}(s) \propto s^\alpha \quad (2)$$

Logo, um gráfico em escalas logarítmicas da flutuação versus s é calculado para representar a existência de autossimilaridade α , que quantifica a natureza das correlações da série temporal. Posteriormente, uma análise logarítmica entre a função flutuação $F(s)$ e o próprio s pode ser analisada de maneira a determinar-se uma relação linear neste gráfico onde o seu coeficiente angular (α) pode indicar auto-similaridade, isto é, para valores de $0 < \alpha < 0.5$ a série representa anti-correlações; $\alpha \approx 0.5$ tem-se o chamado ruído branco, ou seja, um sinal sem nenhuma correlação; para valores $0.5 < \alpha < 1$ tem-se as correlações de longo alcance ou persistentes, e que indicam tendências, que, no caso dos ventos, é um forte indicador de eficácia nos elementos geradores de energia, pois, existirá a persistência ou continuidade na geração bem como velocidades mais facilmente previsíveis; e, finalmente, para $\alpha \geq 1$ tem-se uma correlação, mas sem ser na forma da lei de potência (a exemplo dos ruídos brownianos e a própria turbulência, que não seria uma solução eficaz para os geradores eólicos, pois aumentam sobremaneira os riscos de aceleração da deteriorização do aerogerador).

2.3 O modelo mesoescala WRF

O modelo de mesoescala WRF (versão 3.9) foi configurado com dois domínios

aninhados com resoluções de grade de 9 e 3 km, respectivamente. Interior ao segundo domínio, que abrange todo o estado da Bahia, três domínios foram projetados com resoluções de grade de 1 km, centrados nas três torres anemométricas: os dois domínios maiores têm dimensões horizontais de 223x223 células e 420x420 células, respectivamente, e 60x60 células para os domínios menores envolvendo as torres.

Desta forma, para a inicialização do WRF foram utilizados dados do NCEP (*National Centers for Environmental Prediction*), FNL (*Final Analysis*), com resolução de 0.25°. Os dados de uso do solo foram fornecidos pelo USGS (*United States Geological Survey*) com resolução de 2' para o domínio maior e 30'' para os demais. As simulações incluem 24 h de *spin-up* para obtenção de condições iniciais realistas, ou seja, a simulação para cada mês foi inicializada a partir das 00:00 UTC do último dia do mês anterior. Além disto, foram usadas as seguintes parametrizações físicas: esquema MYJ para *planetary boundary layer* (PBL), Eta para a camada superficial e WDM6 para microfísica (Kitagawa et al., 2017). Vale o registro de que o modelo WRF tem sido usado extensivamente em várias aplicações atmosféricas (Salvador et al., 2016; Ratjiranukool and Ratjiranukool, 2017; Giannaros et al., 2017).

3. RESULTADOS E DISCUSSÕES

Os dados medidos e simulados nas séries que representam a velocidade do vento e a radiação solar, foram submetidos à análise de flutuação destendenciada, ou seja, retirada a tendência da série temporal em diferentes escalas, analisando flutuações intrínsecas dos dados.

Nas Fig. 2, 3, 4 e 5, a seguir, são mostrados comparativos de leis de potência, com a análise do expoente de autosimilaridade, que é o coeficiente angular da reta em ajuste, ao tempo em que são registradas as velocidades dos ventos com dados reais e simulados bem como da radiação solar registrada e simulada na estação meteorológica de Salvador-Ba e com o uso do modelo de mesoescala WRF.

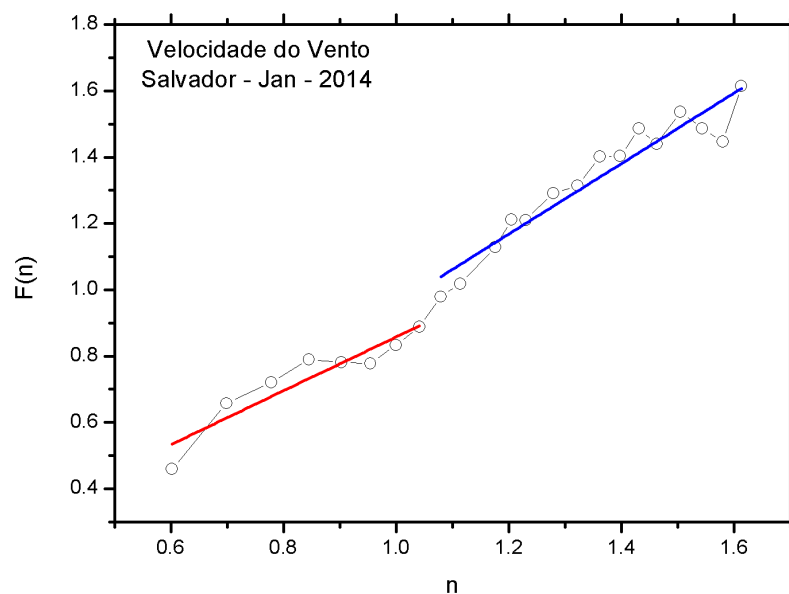


Fig. 2: Velocidade do vento - Jan - 2014

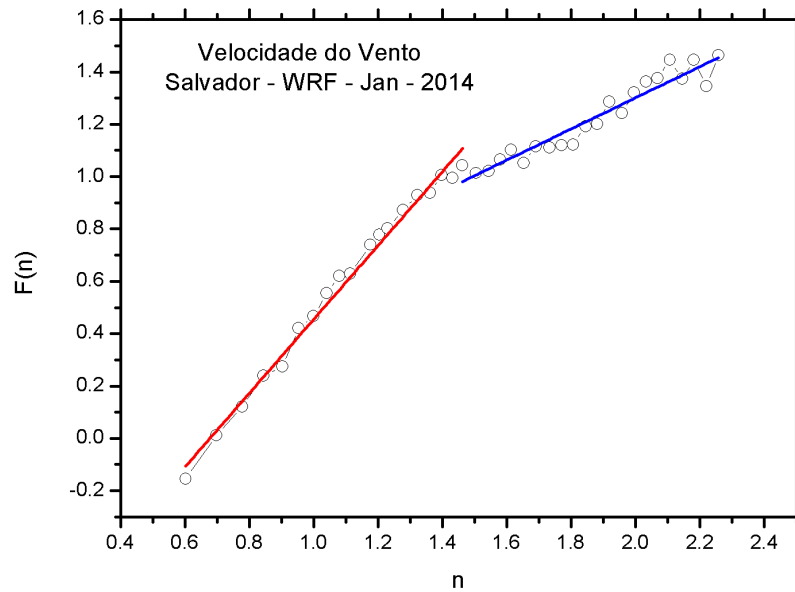


Fig. 3: Velocidade do vento - WRF - Jan - 2014

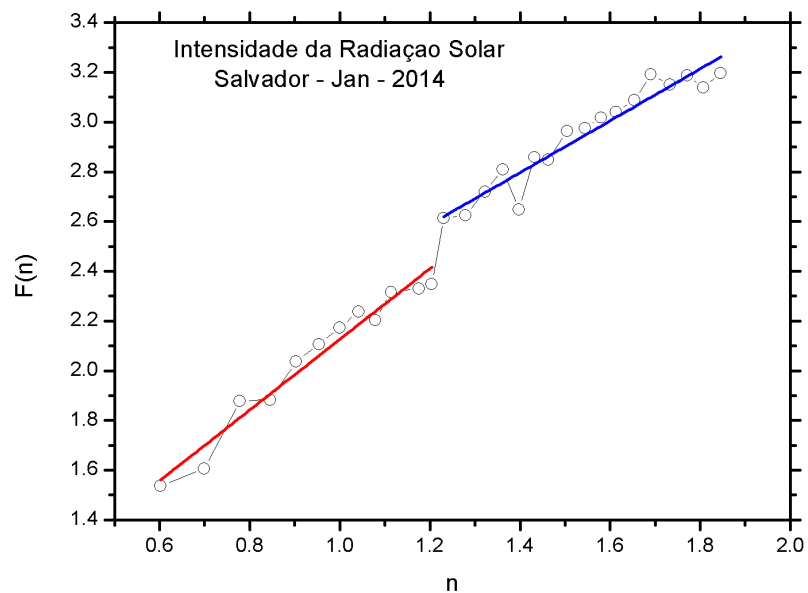


Fig. 4: Radiação solar - Jan - 2014




Fig. 5: Radiação solar - WRF - Jan - 2014

Os valores para a velocidade do vento na estação de Ondina, Salvador, Bahia, conforme verifica na Fig. 2, permite afirmar que foram registrados dois patamares distintos no expoente da lei de potência, tanto para os dados referentes à energia eólica quanto para os dados de energia solar, denominado *crossover*, e já reconhecido em literatura sobre a temática e afins (Kavasseri and Nagarajan, 2004; Santos et al., 2012).

Os valores do coeficiente α para a velocidade do vento nos permite afirmar que no primeiro ajuste (cor vermelha) tem-se 0.812 com erro de 0.126, o que indica um processo de correlação de longo alcance. Logo, valores grandes (ou pequenos) tendem a serem seguidos por valores grandes (ou pequenos), ou seja, tem-se a existência de séries temporais correlacionadas de longo alcance, indicando-se uma série persistente. O segundo ajuste, que ocorre de forma menos intensa, tem-se que visto α é igual a 1.063 com um erro de 0.087, conforme observa-se na Fig. 2, indicando que para valores mais altos do expoente de correlação de longo alcance a dinâmica do sistema é caracterizada por ser não estacionário (regime transitório ou condições transitórias).

Verifica-se também que nos valores simulados no WRF, conforme observa-se na Fig. 3, tem-se o coeficiente α para a primeira curva (em vermelho), de 1.410 com erro de 0.035, indicando que a dinâmica do sistema é caracterizada por ser não estacionário também, enquanto que para a segunda curva (em azul) é de 0.595 com erro de 0.038, mostrando que um processo que apresenta correlação de longo alcance, logo valores grandes (pequenos) tendem a serem seguidos por valores grandes (pequenos), ou seja, tem-se a existência de séries temporais correlacionadas de longo alcance, indicando-se uma série persistente.

Observa-se também que os valores que indicam o início e fim do *crossover* são de aproximadamente 1.05 a 1.10, correspondendo, aproximadamente, à faixa de 16 a 24 h, o que equivale aos valores encontrados na literatura (Santos et al., 2012).

Entretanto, o *crossover* para os valores simulados no WRF variam aproximadamente entre 1.38 a 1.50, o que corresponde à faixa aproximada de 24 a 32 h que são valores superiores aos valores reais. Este cenário está de acordo com o que é preceituado nos dados

simulados, não obstante, os valores acentuados das velocidades em simulação não estão em concordância com a fenomenologia registrada nas bases de dados em consulta, conforme já evidenciado anteriormente.

Não se deve ignorar que, segundo a literatura consultada, a citar Bludszuweit e Navarro (2011), Giannaros et al. (2017), Jaramillo e Borja (2004) e outros, a energia eólica provém da radiação solar, uma vez que os ventos são gerados pelo aquecimento não uniforme da superfície terrestre. Além disto, as características topográficas de uma região também influenciam o comportamento dos ventos uma vez que, em uma determinada área, podem ocorrer diferenças de velocidade, ocasionando a redução ou aceleração na velocidade do vento. Além das variações topográficas e de rugosidade do solo, a velocidade também varia seu comportamento com a altura.

Desta forma a análise do comportamento da radiação solar, registradas nas Fig. 4 e 5, também irá desdobrar-se como sendo uma análise de todo o cenário pois ambas as variáveis estão termodinamicamente indexadas. Desta forma, mantem-se registrado que os valores do coeficiente α para a radiação solar nos permite afirmar que no primeiro ajuste (cor vermelha) tem-se 1.421 com erro de 0.091, e que a dinâmica do sistema é caracterizada por ser não estacionária, enquanto que para a segunda curva (em azul) é de 1.043 com erro de 0.078, indicando também um sistema com a dinâmica não estacionária, ou seja, em regime transitório ou condições transitórias, podendo indicar até mesmo um certo comportamento subdifusivo. No caso de simulação com o WRF tem-se os seguintes coeficientes: 1.528 com erro de 0.022 (curva em cor vermelha) e a segunda curva tem-se 1.395 com erro de 0.107, indicando também o mesmo comportamento citado anteriormente.

4. CONCLUSÕES

No caso das séries de velocidade do vento verificou-se o aparecimento do *crossover*, podendo ter sido ocasionado pelo fato de que o vento local é o resultado de uma interação não linear entre a grande escala (sinótica) e a circulação local, já que espera-se que a característica temporal da velocidade do vento seja fundamentalmente dependente das circulações locais e globais. Entretanto, os efeitos de mesoescala (intermediário entre escala sinótica e microescala) afetam os processos que ocorrem na PBL, que por sua vez afetam diretamente a dinâmica e a termodinâmica da atmosfera (Stull, 1988).

Desta forma, sugere-se que o efeito de *crossover* que aparece neste e em outros trabalhos seja proveniente desta interação, com uma escala de tempo de aproximadamente um ciclo diário (~24 h), o qual é independente de posição geográfica, topografia e altitude. Obviamente, o valor numérico do parâmetro α varia, mas as características subdifusivas e persistentes, representadas pelo fenômeno do *crossover*, permanecem.

Evidencia-se também que em relação às séries de velocidade do vento que os fatores espaciais, tais como elevação, rugosidade do terreno, distância do mar e orografia afetam a magnitude da velocidade do vento bem como a radiação solar, mas não afetam a sua estrutura temporal nem a existência dos ciclos curtos e longos e que o comportamento de escala foi detectado nestas análises preliminares da pesquisa.

Já a análise das séries numéricas para a radiação solar apresentam maior estabilidade e não há o fenômeno de *crossover*, pois nas Fig. 4 e 5, apesar dos indicativos em cores diferenciadas, as variações no expoente de autosimilaridade (coeficiente α) são mínimas e os indicativos de uma dinâmica do sistema caracteriza-se por ser não estacionário.

Não obstante ao exposto, registra-se que ainda existem dados em análises preliminares e que outros volumes de dados ainda estão em tabulação para novas análises, mas tem-se o registro de que os resultados contribuem para uma melhor compreensão da dinâmica da

velocidade do vento e da radiação solar na cidade de Salvador, Bahia, além do fato de que estes registros devem provar-se úteis para a validação de modelos climáticos globais.

Por fim, o método DFA mostra-se como uma ferramenta promissora para ser utilizada na indicação da existência de correlações em uma série temporal da velocidade do vento e da radiação solar, no sentido de predizer os seus pontos de maximização e minimização, além de funções de flutuação temporais das mesmas, servindo, também, como um bom indicador de registro de potencial eólico e solar. Não obstante recomenda-se o aprofundamento das análises com maiores volumes de dados para corroboração dos resultados preliminares atuais.

AGRADECIMENTOS

Este trabalho foi parcialmente financiado pelo Centro Universitário SENAI-CIMATEC, Brasil, pelo INMET, bem como as bolsas da CAPES, as Bolsas da FAPESB e Bolsa HPC ao tempo em que reiteramos e agradecemos a colaboração em estrutura e procedimentos computacionais bem como aos colegas do Centro Universitário SENAI-CIMATEC.

REFERENCIAS

- Azevedo, S.M., Saba, H., Miranda, J.G.V., Nascimento Filho, A.S. and Moret, M.A., (2016). Self-affinity in the dengue fever time series. *Int. J. Mod. Phys. C* 27, 1650143(1-9).
- Bludszweit, H. and Navarro, J.A.D., (2011). A probabilistic method for energy storage sizing based on wind power forecast uncertainty. *IEEE Transactions on Power Systems* 26(3), 1651-1658.
- Brasi. Empresa de Pesquisa Energética. Balanço Energético Nacional 2016. (2016). Ano base 2015: Relatório Síntese.
- Bunde, A., Havlin, S., Kantelhardt, J.W., Penzel, T., Peter, J.H. and Voigt, K., (2000). Correlated and uncorrelated regions in heart-rate fluctuations during sleep. *Physical Review Letters* 85, 3736-3739.
- Bunde, A., Havlin, S., Koscielny-Bunde, E. and Schellnhuber, H.J., (2001). Long term persistence in the atmosphere: global laws and tests of climate models. *Physica A* 302, 255-67.
- Costa, R.L. and Vasconcelos, G.L., (2003). Long-range correlations and non-stationarity in the Brazilian stock market. *Physica A* 329, 231-248.
- Figueiredo, P.H., Moret, M.A., Pascutti, P.G., Nogueira, E. and Coutinho, S., (2010). Self-affine analysis of protein energy. *Physica A* 389, 2682-2686.
- Giannaros, T.M., Melas, D. and Ziomas, I., (2017). Performance evaluation of the Weather Research and Forecasting (WRF) model for assessing wind resource in Greece. *Renewable Energy* 102 A, 190-198.
- Glahn, B., Gilbert, K., Cosgrove, R., Ruth, D. and Sheets, K., (2009). The gridding of MOS-Weather and Forecasting 24(2), 520-529.
- Havlin, S., Buldyer, S.V., Bunde, A., Goldberger, A.L., Ivanov, P., Peng, C.K. and Stanley, H.E., (1999). Application of statistical physics to heartbeat diagnosis. *Physica A* 274, 99-110.
- Ivanov, P., Rosenblum, M.G., Peng, C.K., Mietus, J., Havlin, S., Stanley, H.E. and Goldberger, A.L., (1996). Scaling behavior of heartbeat intervals obtained by wavelet-based time-series analysis. *Nature* 383, 323-327.
- Ivanov, P.C., Yuen, A., Podobnik, B. and Lee, Y.K., (2004). Common scaling patterns in intertrade times of U.S. stocks *Phys. Rev. E* 69, 056107.
- Ivanova, K. and Ausloos, M., (1999). Application of the detrended fluctuation analysis (DFA) method for describing cloud breaking. *Physica A* 274, 349-354.
- Ivanova, K., Ausloos, M., Clothiaux, E.E. and Ackerman, T.P., (2000). Break-up of stratus cloud structure predicted from non-Brownian motion liquid water and brightness temperature fluctuations. *Europhys. Lett.* 52, 40-46.
- Jaramillo, O.A. and Borja, M.A., (2004). Wind speed analysis in La Ventosa, Mexico: a bimodal probability distribution case. *Renewable Energy* 29, 1613-1630.
- Jiang, Z.Q., Chen, W. and Zhou, W.X., (2009). Detrended fluctuation analysis of intertrade durations. *Physica A: Statistical Mechanics and its Applications* 388(4), 433-440.
- Kantelhardt, J.W., Bunde, E.K., Rego, H.H.A. and Havlin S., (2001). Detecting long-range correlations with detrended fluctuation analysis. *Physica A* 295, 441-454.

- Kavasseri, R.G. and Nagarajan, R., (2004). Evidence of crossover phenomena in wind speed data. *IEEE Transactions on Circuits and Systems* 51, 2255-2262.
- Kitagawa, Y.K.L., Nascimento, E.G.S., Souza, N.B.P., Aylas, G.Y.R., Zucatelli, P.J., Salvador, N. and Moreira, D.M., (2017). Assessment of the sensitivity of the WRF model using different PBL schemes over the Metropolitan Region of Salvador. XXXVIII Iberian Latin American Congress on Computational Methods in Engineering, CILAMCE2017. Florianopolis, Brazil. doi:10.20906/CPS/CILAMCE2017-0647.
- Koçak, K., (2009). Examination of persistence properties of wind speed records using detrended fluctuation analysis. *Energy* 34, 1980-1985.
- Koscielny-Bunde, E., Bunde, A., Havlin, S., Roman, H.E., Goldreich, Y., Schellnhuber, H.J., (1998). Indication of a Universal Persistence Law Governing Atmospheric Variability. *Phys. Rev. Lett.* 81, 729-732.
- Kurnaz, M.L., (2004). Application of detrended fluctuation analysis to monthly average of the maximum daily temperatures to resolve different climates. *Fractals* 12, 365-373.
- Liu, Y., Cizeau, P., Meyer, M., Peng, C.K. and Stanley, H.E., (1997). Correlations in economic time series. *Physica A* 245, 437-440.
- Malamud, B.D. and Turcotte, D.L., (1999). Self-affine time series: measures of weak and strong persistence. *Journal of Statistical Planning and Inference* 80(1-2), 173-196.
- Mantegna, R.N. and Stanley, H.E., (2000). *An Introduction to econophysics: correlations and complexity in finance*. Cambridge University Press, 144pp.
- Montanari, A., Rosso, R. and Taqqu, M.S., (2000). A seasonal fractional ARIMA model applied to the Nile River monthly flows at Aswan. *Water Resour. Res.* 36, 1249-1259.
- Moret, M.A., (2014). Self-affinity and nonextensivity of sunspots. *Phys. Lett. A* 378, 494-496.
- Moret, M.A., Moret, G.F., Zebende, E., Nogueira and Pereira, M.G., (2003). Fluctuation analysis of stellar x-ray binary systems. *Phys. Rev. E* 68, 041104.
- Orun, M. and Koçak, K., (2009). Application of detrended fluctuation analysis to temperature data from Turkey. *Int. J. Climatol.* 29, 2130-2136.
- Peng C.K., Buldyrev, S.V., Havlin, S., Simons, M., Stanley, H.E. and Goldberger, A.L., (1994). Mosaic organization of DNA nucleotides. *Physical Review E* 49(2), 1685-1989.
- Ratjiranukool, P. and Ratjiranukool, S., (2017). Evaluating wind speed by WRF model over Northern Thailand. *Energy Procedia* 138, 1171-1176.
- Salvador, N., Reis Jr, N.C., Santos, J.M., Albuquerque, T.T.A., Loriato, A.G., Delbarre, H., Augustin, P., Sokolov, A. and Moreira, D.M., (2016). Evaluation of Weather Research and Forecasting model parameterizations under sea-breeze conditions in a North Sea coastal environment. *J. Meteor. Res.* 30(6), 998-1018.
- Santos, M.O., Stosic, T. and Stosic, B.D., (2012). Long-term correlations in hourly wind speed records in Pernambuco, Brazil. *Physica A* 391, 1546-1552.
- Siwy, Z., Ausloss, M. and Ivanova, K., (2002). Correlation studies of open and closed state fluctuations in an ion channel: Analysis of ion current through a large-conductance locust potassium channel. *Phys. Rev. E* 65, 031907.
- Skamarock, W.C., Klemp, J.B., Dudhia, J., Gill, D.O., Barker, D.M., Huang, X.Y., Wang, W. and Powers, J.G., (2008). A description of the advanced research WRF version 3 (NCAR Technical Note), Mesoscale and Microscale Meteorology Division do NCAR. Boulder, Colorado, USA.
- Stanley, H.E., Buldyrev, S.V., Goldberger, A.L., Havlin S., Peng C.K. and Simons, M., (1999). Scaling features of noncoding DNA. *Physica A* 273, 1-18.
- Stull, R.B., (1988). *An introduction to boundary layer meteorology*. Kluwer Academic Publishers, Dordrecht., 669pp.
- Tsonis, A.A., Roebber, P.J. and Elsner, J.B., (1999). Long-range correlations in the extratropical atmospheric circulation: origins and implications. *Journal of Climate* 12, 1534-1541.
- Zebende, G.F., da Silva, M.V.S, Rosa, A.C.P., Alves, A.S., de Jesus, J.C.O. and Moret, M.A., (2004). Studying long-range correlations in a liquid-vapor-phase transition. *Physica A* 342, 322-328.
- Zebende, G.F., Pereira, M.G., Nogueira, E. and Moret, M.A., (2005). Universal persistence in astrophysical sources. *Physica A* 349, 452-458.

Abstract: *This work shows the positive correlation between the historical and temporal series of velocity and solar energy in the city of Salvador (Bahia). Research and Forecasting through the DFA (Detrended Fluctuation Analysis) method. Preliminary results indicate that the data series are characterized with persistence in speed and solar energy in a satisfactory way for an energy generation, which indicates the feasibility of the learning of matrices of matrices in the local energy.*

Keywords: *Renewable sources, DFA, Complexity, Wind energy, Solar energy.*