



ISSN: 2230-9926

Available online at <http://www.journalijdr.com>

IJDR

International Journal of Development Research

Vol. 11, Issue, 03, pp. 44963-44966, March, 2021

<https://doi.org/10.37118/ijdr.21338.03.2021>



RESEARCH ARTICLE

OPEN ACCESS

UMA PESQUISA SOBRE PREVISÃO DE SÉRIES TEMPORAIS NÃO-ESTACIONÁRIAS VIA MODELOS FUZZY EVOLUTIVOS

*Vania Corrêa Mota

¹Phd in Agricultural Engineering, Adjunct Professor Federal University of Rondônia – UNIR, Department of Mathematics and Statistics, Ji-Paraná, Rondônia, Brazil

ARTICLE INFO

Article History:

Received 27th December, 2020

Received in revised form

17th January, 2021

Accepted 06th February, 2021

Published online 15th March, 2021

Key Words:

Granular Computing, Meteorological Forecast, Online Machine Learning, Fuzzy systems.

*Corresponding author: Vania Corrêa Mota

ABSTRACT

The present work aims to present a brief review on optimal granular evolutionary models that can provide accurate and granular predictions of flow of big meteorological data (big data). This environment is based on the theory of multicriteria optimization and is concerned not only with the accuracy of predictive models, but also with the specificity of information granules, delta-data coverage, and compression and structural evolution of fuzzy rules. The prediction problem is non-stationary and, of course, requires incremental strategies and evolutionary modeling.

Copyright © 2021, Vania Corrêa Mota. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citation: Vania Corrêa Mota. "Uma pesquisa sobre Previsão de Séries Temporais Não-Estacionárias via Modelos Fuzzy Evolutivos", *International Journal of Development Research*, 11, (03), 44963-44966.

INTRODUCTION

Na era da informação, a disponibilidade dos dados tem aumentado exponencialmente. No contexto de meteorologia, tais dados provenientes de estações meteorológicas e satélites devem idealmente ser processados em tempo real para que modelos de predição de valores futuros possam ser desenvolvidos e ter alguma utilidade (Casagrande & Severo, 2018). Um sistema inteligente que análise observações detalhadas, coordenadas geográficas, e um número de variáveis do sistema Terra-Atmosfera pode ser útil para vários propósitos. Em geral, o objetivo é fornecer informações globais continuamente, em tempo real, e com qualidade, tal que a informação chegue aos usuários e permita diferentes tipos de tomada de decisão. Dessa forma, a disseminação de informações, orientado ao usuário, fácil de usar e de baixo custo, gera um grande fluxo de dados meteorológicos. Tanto, dados meteorológicos medidos diretamente, como imagens/produtos e variáveis diversas extraídas de imagens de satélites podem ser acessados. Entretanto um volume de gigabytes é gerado em alguns minutos. Nesse contexto, ressalta-se a importância de algoritmos e modelos que possam lidar com grandes fluxos de dados não-estacionários. Os fluxos de dados exigem algoritmos rápidos, de varredura única dos dados, que identifiquem e armazenem em modelo apenas as informações essenciais no cenário atual. É necessário repensar muitas técnicas existentes de mineração de dados

vistas antes (Leite *et al.* 2011). Pesquisas recentes sobre sistemas granulares evolutivos (Pedrycz, 2010; Leite *et al.* 2010) enfatizam a granulação no espaço e no tempo de dados detalhados e a modelagem a partir de objetos mais grosseiros e rudimentares que os dados. O propósito é simplificar problemas complexos do mundo real e fornecer soluções de baixo custo computacional. Conforme colocado por Zadeh (1997) e Yao (2005), a computação granular explora a tolerância à imprecisão, incerteza e a verdade parcial para obter rastreabilidade, robustez e melhor relacionamento com o real. A flexibilidade de lidar com a dinâmica de um sistema físico dentro de um ambiente granular nos permite descrever grânulos em diferentes domínios de aplicação sem conhecimento especialista sobre o problema em questão. O ambiente *on-line* impõe restrições de tempo e memória, bem como requisitos de compressão. Isto inspira visões granuladas dos dados e a aceitação da incerteza. A abordagem evolutiva granular ótima (eOGS - *Evolving optimal granular systems*) baseada em conjuntos *fuzzy* adaptativos pertence ao *framework* da computação granular porque usa hiper-caixas *fuzzy* para construir mapas granulares que associam dados granulares de entrada a dados granulares de saída (Leite *et al.* 2011).

O desenvolvimento de modelos eOGS considera um problema de otimização multiobjetivo que inclui a especificidade da informação no sentido de Yager (2014), a compactação estrutural do modelo, e a variabilidade e delta-cobertura dos dados no processo de modelagem de fluxos de dados. Modelos eOGS podem ser combinados em uma estrutura paralela (ensemble), onde cada modelo eOGS bases oferece

uma contribuição. Estas são combinadas usando operadores de agregação. Abordagens de modelagem eOGS individuais ou na forma de ensemble são apropriadas para lidar com problemas de bases de dados grandes, desbalanceadas, e não-estacionárias, como aquelas provenientes de aplicações meteorológicas. Diante do exposto, essa pesquisa tem como objetivo apresentar uma breve revisão sobre modelos evolutivos granulares ótimos que podem prover previsões precisas e granulares (invólucros) de fluxo de dados meteorológicos grandes (*big data*).

Aplicações relacionados a modelos evolutivos no contexto de meteorologia: Garcia *et al.* (2019) desenvolveram um modelo denominado de *Fuzzy Granular Predictor* (eFGP) que é baseado em regras *fuzzy* granular em evolução, sendo modificado para aproximação de funções e previsão de séries temporais em um contexto *on-line* onde valores podem estar ausentes. Usaram três conjuntos de dados de referência para avaliar a eficiência do eFGP, dentre eles o conjunto de dados meteorológicos Death Valley (EUA) com registros da temperatura média mensal. Verificaram que o eFGP supera outros métodos inteligentes em evolução. O eFGP em evolução lida com valores únicos e múltiplos ausentes em amostras de dados, desenvolvendo polinômios consequentes de prazo reduzido e utilizando grânulos que variam no tempo. O algoritmo de aprendizado eFGP adapta gradualmente os grânulos e outros parâmetros associados às regras para que o modelo *fuzzy* capture ocorrências recentes sem esquecer comportamentos anteriores (Garcia *et al.* 2019).

Em Leite & Skrjanc, (2019) são avaliados operadores Média Ponderada Ordenada (OWA), Média Aritmética Ponderada, Mediana, e OWA Centralizado Não-Inclusivo Linear. Algumas funções de agregação usam pesos específicos baseados na relevância dos modelos eOGS base para excluir valores extremos. Os pesos associados a alguns operadores de agregação são adaptados ao longo do tempo com base em um problema de programação quadrática e nos dados em uma janela deslizante (Leite & Skrjanc, 2019). Os autores usaram eOGS, modelos granulares *fuzzy* ótimos, baseados em regras com diferentes funções e restrições objetivas, que evoluíram a partir de fluxos de dados e fizeram previsões para séries temporais de temperatura média diária, umidade do ar e velocidade do vento de diferentes condições climáticas em estações como Paris-Orly, Frankfurt-Main, Reykjavik e Oslo-Blindern, concluíram que o modelo forneceu previsões numéricas precisas.

Soares *et al.* (2017) realizou a comparação em função do tempo de processamento e da precisão entre os modelos TEDA para predição (TEDA Predict) (Angelov *et al.* 2013; Bezerra *et al.* 2016), os métodos evolutivos eTS (Angelov & Zhou, 2006) e xTS (Angelov & Zhou, 2006) - método *Fuzzy Takagi-Sugeno* Estendido para prever a temperatura média mensal em diferentes regiões do Brasil. Verificaram que o modelo TEDA apresentou melhor desempenho em comparação com os métodos eTS e xTS considerando as estações de São Paulo/SP, Manaus/AM e Porto Alegre/RS, entretanto, os métodos evolutivos eTS e xTS apresentaram maior desempenho e rapidez para aprender a partir do fluxo de dados (Soares *et al.* 2017). Os autores concluíram que o estudo dessa variável climática e o uso dessa modelagem é pertinente no caso de previsão no ambiente agrícola, sendo interessante para produtores e para os cidadãos em suas atividades econômicas.

Medina *et al.* (2019) apresentaram uma nova metodologia de mineração de fluxo de dados, onde os modelos são aprendidos de forma incremental e adaptativa, para a previsão da velocidade máxima do vento, a fim de disparar um alerta precoce para condições climáticas extremas nas oito Ilhas Canárias. Quando comparado a aplicação da metodologia baseada no fluxo de dados (“adaptativo”) versus o método linear “acumulativo” os resultados indicaram que a estratégia adaptativa sempre foi superior. Concluíram que o modelo adaptativo pode ser generalizável, pois parece funcionar bem para a rede geograficamente dispersa de estações meteorológicas, para que os modelos de velocidade do vento possam ser aplicados a diferentes cenários, uma vez treinados (Medina *et al.* 2019).

Soares *et al.* (2018) estudaram um método de modelagem evolutiva baseado em conjuntos nebulosos gaussiano, FBEM-G, para prever trilhas de ciclones tropicais com 6 horas de antecedência e verificaram que o método é útil para determinar áreas de risco e ações a serem tomadas para avisos e evacuações. O estudo de previsão de atividades de furacões é significativo para fazer alertas eficazes e planejamento de mitigação de desastres para determinadas áreas vulneráveis e povoadas, por exemplo áreas costeiras, se tornando um desafio para meteorologistas e pesquisadores.

Niksaz & Latif (2014) estudaram o sistema de inferência neuro-*fuzzy* adaptativo (do inglês *Adaptive Neuro-Fuzzy Inference System - ANFIS*) para avaliar eventos de chuva, para valores coletados de hora em hora, gerando funções de associação para cada parâmetro de entrada (umidade relativa, cobertura total de nuvens, temperatura do ponto de orvalho, temperatura e pressão da superfície) e a saída fornecendo eventos não recorrente de chuva. Os autores verificaram que, para o uso dos modelos baseados no sistema ANFIS, é desejável mesclar as experiências de meteorologistas e estudos teóricos com eficiência e precisão dos sistemas computacionais por procedimento baseado em algoritmo. Os resultados obtidos demonstram uma alta concordância com os dados reais (Niksaz & Latif, 2014).

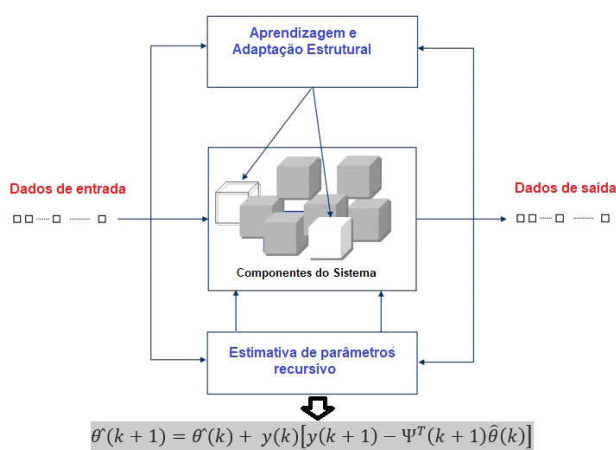
Goyal *et al.* (2014) avaliaram quatro novas técnicas de aprendizado de máquina, redes neurais artificiais (RNA), mínimos quadrados - regressão vetorial de suporte (LS-SVR), lógica *fuzzy* e ANFIS para estimar a evaporação diária em climas subtropicais. Observaram com a comparação que as abordagens de lógica *fuzzy* e LS-SVR podem ser empregadas com sucesso na modelagem do processo diário de evaporação a partir dos dados climáticos disponíveis. Além disso, os resultados mostraram que os modelos de aprendizado de máquina superaram os métodos empíricos tradicionais de Hargreaves e Samani, bem como o método de Stephens-Stewart (Goyal *et al.* 2014).

Bartoletti *et al.* (2018) utilizaram uma rede neuro- *fuzzy* (ANFIS) combinada com a Análise de Componentes Principais (PCA) para modelar a relação entre a precipitação de entrada e o fluxo de saída em uma maneira compacta e flexível. Os pesquisadores observaram que essa combinação representa uma abordagem eficiente orientada a dados para modelagem de montagem de fluxo e a precipitação equivalente obtida pela redução do PCA é eficaz no treinamento da rede ANFIS e no controle de sua precisão. Leite *et al.* (2020) introduziram um método de aprendizado incremental para a construção ideal de sistemas granulares baseados em regras a partir de fluxos de dados numéricos. O método é desenvolvido dentro de uma estrutura de otimização multiobjetivo, considerando a especificidade das informações, a compactação do modelo, a variabilidade e a cobertura granular dos dados. Segundo os autores esse método pode ser útil na modelagem de séries temporais, identificação dinâmica de sistemas, análise preditiva e controle adaptativo.

Aprendizagem incremental – on-line: A principal característica de uma aprendizagem incremental está na sua estrutura de acumular conhecimento de forma dinâmica. De acordo com Stange & Neto (2011) esta consiste em técnicas para fornecer ao mecanismo de aprendizagem a disposição de tirar informações adicionais a partir dos dados, sempre que surgirem mais dados ou novos dados, ou quando se julgar apropriado. Os algoritmos de aprendizagem incremental são basicamente guiados por regras, e sua base de conhecimento precisa ser atualizada. No caso de dados meteorológicos, as leituras são realizadas a todo momento. Por exemplo, os dados de previsão de direção e velocidade do vento que são essenciais para tomada de decisão em aeroportos, as informações precisam ser dinâmicas e atualizadas. Os dados estão em constante alteração, e necessitam de modelos de previsão mais precisos e adaptativos. Diante disso, surge os chamados sistemas *fuzzy* evolutivos, do inglês *Evolving Fuzzy Systems – EFS*, que utilizam mecanismos para treinar e atualizar continuamente os modelos de maneira on-line, de forma que estes vão se adaptando a dinâmica das mudanças dos fluxos de dados. Estes fluxos são compactados com alguns grânulos cuja localização e a granularidade refletem a estrutura dos dados, podem ser representadas como dados *fuzzy*, intervalar ou numéricos a serem levados em

consideração na estrutura granular *fuzzy* (Garcia *et al.* 2019). Vale ressaltar que o objetivo da modelagem com aprendizado incremental - on-line é a construção de modelos que possuem ótima capacidade de generalização frente a novos dados. Essa modelagem granular baseada em conjuntos *fuzzy* em evolução foi proposta em Leite *et al.* (2011) e Leite *et al.* (2012) como uma estrutura para modelar fluxos de dados nos quais os valores medidos são inerentemente incertos. Com o acréscimo do número de aparelhos (*data logger*) capazes de coletar dados continuamente - incluindo variáveis que atinge o clima - um grande volume de dados tem sido gerado/criado (Mota *et al.* 2017; Leite *et al.* 2020). E dessa forma, a quantidade de dados está aumentando a uma taxa que às vezes ultrapassa a capacidade de armazenamento disponível (Leite *et al.* 2020). Um meio de tratar esses amplos volumes de dados é através da aplicação de uma classe de métodos computacionais conhecidos como métodos de aprendizagem incremental ou sistemas inteligentes evolutivos (Kasabov, 2007; Angelov & Filev, 2010; Leite *et al.* 2015). A abordagem evolutiva é uma maneira competente/eficiente de tratamento de fluxos de dados devido à sua habilidade de adaptar modelos à diferentes situações e prover uma resposta rápida às mudanças, isto é, às alterações de conceito (Lughofer & Angelov, 2011; Leite *et al.* 2016; Mota *et al.* 2017).

Modelos eOGS: Os sistemas granulares ótimos em evolução (eOGS) analisam a otimização multiobjectivo, a especificidade das informações dos dados, a compactação do modelo e a variabilidade e cobertura destes no processo de modelagem de fluxos de dados (Leite & Skrjanc, 2019). São úteis na modelagem de séries temporais, análise preditiva e controle adaptativo (Leite *et al.* 2020). Atualmente com os trilhões de dados que são gerados diariamente, ocorre um crescimento exponencial da quantidade de dados, dessa forma, os sistemas inteligentes como eOGS cujos parâmetros e estrutura mudam, isto é, sofrem uma adaptação contínua, são úteis para serem utilizados em previsão de valores futuros de séries temporais não estacionárias. Os fluxos de dados não-estacionários, chegam constantemente, podem vir desordenados, com dados faltantes, e ao longo do tempo pode ocorrer uma mudança na sua distribuição. A abordagem evolutiva de dados provê a aproximação funcional granular e singular, com a descrição linguística de um sistema, nesse caso, os grânulos são os conjuntos de amostras com características similares, e para series temporais utiliza-se a base de regra IF-THEN. Os modelos baseados em regras, para atualizar a parte anterior de algumas de suas regras sempre que surgem novos dados, utilizam um algoritmo de clusterização recursivo não supervisionado, e dessa forma, ao criar novas regras existe sempre a possibilidade no caso de uma amostra de dados transmitir informações significativamente diferentes (Leite *et al.* 2020). Em particular, a evolução de sistemas baseados em regras *fuzzy* são sistemas em evolução nos quais os componentes do sistema são regras *fuzzy*, na figura 1 pode ser observado a ideia de adaptação estrutural e paramétrica de um sistema geral em evolução.



Fonte: Adaptado de Leite *et al.* (2020)

Figura 1. Sistema em evolução

Pode-se ter disponível a cada instante uma estimativa calculada a partir da estimativa anterior e dos novos dados coletados e escrevendo a estimação não recursiva para nova estimação e a velha estimação e subtraindo um do outro obtém-se o algoritmo recursivo de estimação de parâmetros, em que $\hat{\theta}$ é o vetor de correção, $\hat{\theta}$ é a nova média e $\hat{\theta}$ é a predição um passo à frente da nova medida, para maiores detalhes ver Ljung (1999).

No modelo eOGS a adaptação das regras incide em ampliar ou contrair as fronteiras dos grânulos e, simultaneamente, alterar os coeficientes das funções locais para melhor adequação a novos desempenhos (Leite & Skrjanc, 2019). Vários modelos evolutivos são utilizados para previsão de séries temporais aplicados a dados meteorológicos como: DENFIS (Kasabov & Song, 2002), FBeM – G (Soares *et al.* 2018), IBeM (Leite, Costa & Gomide, 2010), eFGP (Garcia *et al.* 2019) e eGNN (Leite *et al.* 2012), entre outros, que nesta revisão serão chamados de modelos evolutivos alternativos. Um breve resumo desses modelos evolutivos alternativos será apresentado abaixo:

• **Dynamic Evolving Neural-Fuzzy Inference System (DENFIS):** Proposto por Kasabov & Song (2002), o modelo DENFIS (*Dynamic Evolving Neural-Fuzzy Inference System*) é utilizado para o aprendizado *on-line* e *off-line* de novos comportamentos das séries temporais. A essência da informação do fluxo de dados é capturada em um modelo DENFIS. Segundo Kasabov & Song (2002), o modelo DENFIS foi idealizado baseado na ideia de que, conforme um vetor de dados diferente é apresentado, um modelo *fuzzy* local (uma regra *fuzzy* funcional) é criado dinamicamente. A estimação global do modelo é baseada em m regras *fuzzy* desenvolvidas durante estágio de aprendizagem ou de operação do preditor. O modelo evolui no tempo por meio de um algoritmo de aprendizado recursivo, que pode ser supervisionado ou não. Durante sua operação, novas regras *fuzzy* são criadas ou adaptadas, e podem ser extraídas do modelo durante ou após o estágio de aprendizagem. O método de agrupamento evolutivo ECM (Evolving Clustering Method) e uma variação recursiva de algoritmo de Mínimos Quadrados são utilizadas para adaptação do modelo (Kasabov, 2007; Leite *et al.* 2012).

Fuzzy Set Based Evolving Modeling Gaussin (FBeM – G): O FBeM é uma abordagem de modelagem evolutiva que produz grânulos de informação de nível superior com base em dados mais detalhados e algoritmo de aprendizagem recursiva (Leite *et al.* 2011). No modelo FBeM-G a modelagem em evolução produz grânulos difusos gaussianos com base no fluxo de dados, consiste em regras *fuzzy If-Then* extraídas incrementalmente dos dados, e neste caso um algoritmo de aprendizagem incremental lança sua estrutura de regras para rastrear novos conceitos, lidar com a incerteza e fornecer pontos e previsões granulares de séries temporais (Soares *et al.* 2018). O aprendizado FBeM-G começa sempre do zero, isto é, nenhuma regra precisa ser planejada antecipadamente, os grânulos e as regras são criados e adaptados dinamicamente de acordo com o fluxo de dados (Soares *et al.* 2018). Sempre que um novo dado amostral chega no sistema, um mecanismo de decisão é acionado e uma regra é inserida na estrutura do modelo ou parâmetros de uma regra existente é adaptada (Soares *et al.* 2018).

Interval – Based Evolving Modeling – IBeM: O algoritmo IBeM é capaz de criar/adaptar incrementalmente os parâmetros e a estrutura do modelo é de simples aprendizagem, sendo particularmente adequado para processar o fluxo de dados em tempo real. O IBeM trabalha com a imprecisão e fornece aproximações granulares de funções não lineares, sua análise de intervalo provê limites rigorosos sobre erros de aproximação, erros de arredondamento e imprecisões nos dados propagados durante os cálculos (Leite *et al.* 2010). Esta abordagem é útil para estender o modelo atual, para evitar lacunas e para reduzir o efeito da sequência de entrada de dados (Leite *et al.* 2010).

Evolving Fuzzy Granular Predictor (eFGP): Proposto por Garcia *et al.* (2019), o modelo eFGP (*evolving Fuzzy Granular Predictor*) é um algoritmo recursivo para a adaptação de modelo *fuzzy* modificado, é

útil para previsão. Também pode ser utilizado para imputar valores faltantes na série temporal. No modelo *eFGP*, as regras são criadas e atualizadas simultaneamente (Garcia et al. 2019).

Evolving Granular Neural Networks (eGNN): O *eGNN* foi desenvolvido por Leite (2012), são redes neurais granulares que codificam um conjunto de regras fuzzy em suas estruturas, e consequentemente o seu processamento neural está em conformidade com o de um sistema de inferência *fuzzy* que forma funções de agregação. Tem sido muito utilizado como um algoritmo incremental para aprendizagem de fluxo de dados, que pode ser numérico ou *fuzzy* (Leite, 2012). Como todo modelo evolutivo as regras e os grânulos *fuzzy* são produzidos e atualizadas simultaneamente. De acordo com Leite et al. (2010); Leite (2012); Leite et al. (2020) o modelo fornece várias características que demonstram sua capacidade de processamento e interpretabilidade dos dados, em resumo o modelo pode tratar um grande fluxo de dados computacionalmente, melhora a explicabilidade por meio de um grânulo local com modelos de regras linguísticas e apresenta um custo reduzido de dados em processamento em comparação a métodos não evolutivos.

REFERENCES

- Angelov, P., Filev, D., Kasabov, N. 2010. "Evolving Intelligent Systems: Methodology and Applications," Wiley-IEEE Press, 2010.
- Angelov, P., Skrjanc, I., Blazic, S. 2013. "Robust Evolving Cloud-Based Controller for a Hydraulic Plant," *IEEE - Conference on Evolving and Adaptive Intelligent Systems (EAVIS'13)*, 2013, pp. 1-8.
- Angelov, P., Zhou, X. 2006. "Evolving Fuzzy-Rule-Based Classifiers from Data Stream," *IEEE Transactions on Fuzzy Systems*, 16, 6, 2006, pp. 1462-1475.
- Bartoletti, N., Casagli F., Marsili-Libelli S., Nardi A., Palandri L. 2018. Data-driven rainfall/runoff modelling based on a neuro-fuzzy inference system, *Environmental Modelling & Software*, 106, 2018, pp. 35-47.
- Bezerra, C. G., Costa, B. S., Guedes, L. A. 2016. "A New Evolving Clustering Algorithm for Online Data Streams," *IEEE Conference on Evolving and Adaptive Intelligent Systems (EAVIS'16)*, 2016, pp. 1-7.
- Casagrande, A., Severo, T. C., 2018. "Desenvolvimento de uma estação meteorológica com supervisor e base de dados," *VII Congresso Brasileiro de Energia Solar*, Gramado, 2018.
- Garcia, C., Esmin, A., Leite, D., Škrjanc, I. 2019. "Evolvable fuzzy systems from data streams with missing values: With application to temporal pattern recognition and cryptocurrency prediction," *Pattern Recognition Letters*, 128, 2019, pp. 278-282.
- Goyal, M. K., Bharti, B., Quilty, J., Adamowski, J., Pandey, A. 2014. "Modeling of daily pan evaporation in sub677tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS," *Expert Systems with Applications*, 41, 67811, 2014, pp. 5267-5276.
- Kasabov, N. 2007. *Evolving Connectionist Systems: The Knowledge Engineering Approach*. Springer Science & Business Media, 2007.
- Kasabov, N., Song, Q. 2002. "DENFIS: Dynamic evolving neural-fuzzy inference system and its application for time-series prediction," *IEEE Transactions on Fuzzy Systems*, 10, 2, 2002, pp. 144 - 154.
- Leite, D., Costa, P., Gomide, F. 2010. "Granular approach for evolving system modeling," In: *E. Hullermeier, R. Kruse, F. Hoffmann (Eds.), Lecture Notes in AI*, 6178, 2010, pp. 340 - 349.
- Leite, D., Gomide, F., Ballini, R., Costa, P. 2011. "Fuzzy granular evolving modeling for time series prediction," *IEEE Int. Conf. Fuzzy Systems*, 2011, pp. 2794-2801.
- Leite, D., Costa, P., Gomide, F. 2012. "Evolving Granular Neural Network for Fuzzy Time Series Forecasting," *IEEE World Congress on Computational Intelligence - Brisbane - AU*, 2012, pp. 1-8.
- Leite, D. 2012. *Evolving granular systems*. Tese (doutorado) Universidade Federal de Campinas, Departamento de Engenharia Eletrica e de Computação, Campinas/SP.
- Leite D., Palhares, R., Campos, V., Gomide, F. 2015. "Evolving Granular Fuzzy Model based Control of Nonlinear Dynamic Systems," *IEEE - Transactions on Fuzzy Systems*, 23, 4, 2015, pp. 923-938.
- Leite, D., Santana, M., Borges, A., Gomide, F. 2016. "Fuzzy Granular Neural Network for Incremental Modeling of Nonlinear Chaotic Systems," *IEEE - International Conference on Fuzzy Systems*, 2016 pp. 64-71.
- Leite, D., Skrjanc, I., 2019. Ensemble of evolving optimal granular experts, OWA aggregation, And time series prediction, *Information Sciences*, 504, 2019, pp. 95 - 112.
- Leite, D., Andonovski, G., Skrjanc I., Gomide, F. 2020. "Optimal Rule-Based Granular Systems from Data Streams," *IEEE Transactions on Fuzzy Systems*, 28, 3, 2020, pp. 583-596.
- Ljung, L. 1999. *System Identification*. Prentice-Hall, Upper Saddle River, 1999.
- Lughofer, E., Angelov, P. 2011. "Handling Drifts and Shifts in Online Data Streams with Evolving Fuzzy Systems," *Applied Soft Computing*, 11, 2, 2011, pp. 2057-2068.
- Medina, J. J. S., Montenegro, J. A. G., Rodriguez, D. S., González, I. G. A., Mesa, J. L. N., "Data Stream Mining Applied to Maximum Wind Forecasting in the Canary Islands," *Sensor*, 19, 2388, 2019, pp. 1-21.
- Mota, V. C., Soares, E. A., Leite, D. F. 2017. "Modelagem fuzzy incremental para previsão climática," *XLVI Congresso Brasileiro de Engenharia Agrícola - CONBEA*, Maceió, 2017, pp. 1-10.
- Niksaz, P., Latif, A. 2014. "Rainfall Events Evaluation Using Adaptive Neural-Fuzzy Inference System," *J. Information Technology and Computer Science*, 09, 2014, pp. 46-51.
- Pedrycz, W. 2010. "Evolvable fuzzy systems: some insights and challenges," *Evolving Systems*, 1, 2, 2010, pp. 73 - 82.
- Rathnayake, U. 2019. "Comparison of Statistical Methods to Graphical Methods in Rainfall Trend Analysis: Case Studies from Tropical Catchments," *Advances in Meteorology*, 2019, pp. 1-10.
- Soares, E., Mota, V., Pouças, R., Leite, D. 2017. "Cloud-Based Evolving Intelligent Method for Weather Time Series Prediction," *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 2017, pp. 1-6.
- Soares, E. A., Camargo, H. A., Camargo, S. J., Leite, D. F., 2018. Incremental Gaussian Granular Fuzzy Modeling Applied to Hurricane Track Forecasting," *IEEE International Conference on Fuzzy Systems (FUZZY-IEEE)*, 2018, pp. 1-6.
- Stange, R. L., Neto, J. J., 2011. "Aprendizagem Incremental usando Tabelas Decisão Adaptativas," *5º Workshop de Tecnologia Adaptativa - WTA*, 2011, pp. 35 - 42.
- Zadeh, L. A., 1997. "Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic," *Fuzzy Sets and Systems*, 19, 1997, pp. 111 - 127.
- Yao, Y. Y. 2005. "Perspectives of granular computing," *IEEE International Conference on Granular Computing*, (2005) 85-90.
- Yager, R. R. 2014. "Generalized OWA aggregation operators," *Fuzzy Optimization and Decision Making*, 3, 2014, pp. 93-107.
