

# INTEGRAÇÃO ENTRE PRÉ-PROCESSADORES E WORKFLOWS CIENTÍFICOS PARA AUXILIAR A GERÊNCIA DE DADOS METEOROLÓGICOS NO ESTADO DO RIO DE JANEIRO

Fillipe Souza da Silva Dornelas<sup>1</sup>; Sergio Manuel Serra da Cruz<sup>2</sup>; Gustavo Bastos Lyra<sup>4</sup> & Ednaldo Oliveira dos Santos<sup>4,5</sup>

<sup>1</sup>BolsistaPROIC/UFRRJ, <sup>2</sup>Discente do Curso de Sistemas de Informação/UFRRJ; <sup>3</sup>Professor do DEMAT/ICE/UFRRJ, <sup>4</sup>Professor do DCA/IF/UFRRJ; <sup>5</sup>Professor orientador.

*Palavras-Chave: chuva, qualidade de dados, workflows, proveniência.*

## Introdução

A busca pelo conhecimento científico faz com que instituições acadêmicas e científicas procurem não só novas formas de gerenciar crescentes volumes de dados em seus experimentos científicos, como também reduzir o tempo e os custos necessários para seu tratamento (FENG *et al.*, 2004). A adoção de procedimentos computacionais apoiados por *workflows* científicos permite atingir ganhos de produtividade e qualidade na condução desses experimentos. Desta forma, a gerência adequada dos descritores de proveniência representam um diferencial (CRUZ, 2011).

No entanto, a gerência efetiva de experimentos científicos que manipulam grandes volumes de dados na área de Meteorologia, requer novas abordagens, como por exemplo, técnicas de distribuição de dados e processos, mecanismos de coleta de descritores de proveniência, entre outros. Portanto, mapear, caracterizar e adicionar qualidades aos diferentes tipos de dados meteorológicos e agregar descritores de proveniências correlacionados com os experimentos científicos dessa área é um problema ainda em aberto que deve ser pesquisado.

Em vista disso, este trabalho tem como objetivo desenvolver *workflows* e integrar seus resultados com o sistema *Meteoro* (LEMON FILHO *et al.*, 2013) para serem utilizados em experimentos científicos na área de Meteorologia que usam grandes massas de dados coletados a partir de estações meteorológicas existentes no Rio de Janeiro e disponibilizados em bases públicas de dados.

## Metodologia

Os dados utilizados nesta pesquisa fazem parte de séries de dados meteorológicos coletados em diversas estações pluviométricas distribuídas no estado do Rio de Janeiro (latitudes 20° 45' e 23° 21' S e longitudes 40° 57' e 44° 53' W). As séries climáticas de precipitação pluvial foram obtidas em arquivos de textos disponíveis no banco de dados da Agência Nacional de Águas (ANA), com auxílio da ferramenta Hidroweb (<http://hidroweb.ana.gov.br>). Esses dados são obtidos de arquivos textos estruturados, e incorporados ao sistema de pré-processadores, previamente desenvolvido pelo grupo de pesquisa, denominado *Meteoro* (LEMON FILHO *et al.*, 2013).

A metodologia de trabalho a ser aplicada nesse estudo está baseada na proposta de desenvolvimento de modelos semânticos bem fundamentados para a representação de descritores de proveniência de dados de experimentos científicos desenvolvida por Cruz (2011) e Cruz *et al.* (2011, 2012). Em vista disso, para o desenvolvimento dos *workflows* científicos está sendo usado o VisTrails (BAVOIL *et al.*, 2005) para operar sobre os dados meteorológicos obtidos no estado do Rio de Janeiro, para gerar dados livres de falhas. Escolheu-se este sistema por ser um sistema aberto, de amplo uso e sem custos de licenciamento.

## Resultados e Discussão

Após análise dos dois sistemas gerenciadores de workflow científico conforme item anterior, foi verificado que o melhor sistema para o desenvolvimento do workflow científico em nosso trabalho foi o *VisTrails*. Isso se justifica porque ele facilita o sistema e permite a visualização da proveniência retrospectiva dos *workflows* e execução de suas versões, sendo capaz de expressar resultados de modo gráfico. Além disso, ele possibilita definir um *workflow* concreto e controlar alterações, ou seja, diferentes versões, de modo visual através de árvores.

Um dos desafios dessa pesquisa foi a integração de um workflow desenvolvido em *VisTrails* e a execução de pelo menos parte do modelo estatístico usando outros recursos, uma vez que o *VisTrails* não possui uma ferramenta específica para este tipo de aplicação.

Com isso foi necessário criar um sub-workflow de integração em código *python* usando o componente “*python source*” do próprio *VisTrails*, tanto para a execução local quanto para a execução em uma máquina remota. Naturalmente que após a aplicação dos métodos estatísticos são gerados novos arquivos, que por sua vez, servem de entrada para o workflow, pois contém dados curados, que servem como resultado e fazem parte também da coleta de proveniência dos dados do experimento, conforme figura ao lado.



## Conclusão

A abordagem proposta apresenta o paradigma dos *workflows* científicos voltados para tratar problemas que manipulam grandes volumes de dados meteorológicos e capturar informações de proveniência relacionadas às operações de criação, modificação e exclusão de arquivos, além de relacioná-las aos dados de proveniência e retrospectiva do *workflow*.

Atualmente a integração entre os sistemas *Meteoro* e *Workflow* são feitas através de um arquivo de texto que após ser gerado pelo *Workflow*, o mesmo é carregado no sistema *Meteoro*. Através dos testes e avaliações verificou-se que o melhor sistema a ser usado no desenvolvimento dos *workflows* científicos sobre os dados meteorológicos no estado do Rio de Janeiro é o *VisTrails*. Para a integração entre os sistemas, o arquivo gerado é devidamente identificado pelo sistema *Meteoro* e para fins de proveniência é feita a identificação de cada arquivo usado para a geração dos resultados dos métodos estatísticos.

A próxima etapa será a integração no nível de banco de dados, onde ambos os sistemas compartilhem a mesma base de dados e possam assim ter mais autonomia na execução de seus procedimentos.

## Agradecimentos e Auxílio Financeiro

Agradecemos à FAPERJ pelo financiamento do Projeto “Uso de *Workflows* Científicos e Ontologias em Experimentos Científicos baseados em Grandes Massas de Dados Meteorológicos” e ao Programa PROIC/UFRRJ pela bolsa de iniciação científica do autor principal deste trabalho. Agradecemos também a Fábio Cardozo da Silva, Mestrando do PPGMMC/UFRRJ, em relação ao desenvolvimento do workflow científico.

## Referências Bibliográficas

- BAVOIL, L.; CALLAHAN, S. P.; CROSSNO, P. J. *et al.*, 2005. *VisTrails: Enabling Interactive Multiple-View Visualizations*. Proceedings of IEEE Visualization, pp. 135-142.
- CRUZ, S.M.S. *Uma Estratégia de Apoio à Gerência de Dados de Proveniência em Experimentos Científicos*. Tese de Doutorado. PESC/COPPE-UFRJ, 2011.
- CRUZ, S.M.S.; SILVA, C.E.P.; OLIVEIRA, D. *et al.*, 2011. Capturing Distributed Provenance Metadata from Cloud-Based Scientific Workflows. *J. Inform. and Data Management*, v. 2, n. 1, pp. 43-50.
- CRUZ, S.M.S.; MACHADO, M.L.M.; MATTOSO, M., 2012. A Foundational Ontology to Support Scientific Experiments. In: Proceedings of Joint V Seminar on Ontology Research in Brazil and VII International Workshop on Metamodels, Ontologies and Semantic Technologies, pp. 144-155, Recife, Pernambuco.
- FENG, S.; HU, Q.; QIAN, W., 2004. Quality Control of Daily Meteorological Data in China, 1951–2000: A New Dataset. *International Journal of Climatology*, p. 853-870. 14 abr. 2004
- LEMO FILHO, G. R.; PRECINOTO, R. S.; CORREIA, T. P.; SANTOS, E. O.; LYRA, G. B. & CRUZ, S. M. S., 2013. Assimilação, Controle de Qualidade e Análise de Dados de Meteorológicos Apoiados por Proveniência. XXXIII CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO/BreSci – VII Brazilian e-Science Workshop, Maceió/AL, Julho/2013.