

## INFERÊNCIA DIFUSA COMO SUPORTE À DESCOBERTA DE POSSÍVEIS SNPs EM SEQUÊNCIAS DE cDNA

**Wagner Arbez**, Michel Eduardo Beliza Yamagishi , Marcos Vinícius G. Barbosa da Silva  
Empresa Brasileira de Pesquisa Agropecuária, Rua Engenho do Nascimento, 610, 36038-330, Juiz de Fora, MG  
E-mail: arbez@cnpgt.embrapa.br, michel@cnpgt.embrapa.br, marcos@cnpgt.embrapa.br

**Láz Alfreto Vidal de Carvalho**  
Universidade Federal do Rio de Janeiro, Centro de Tecnologia - Bloco H-319, 21945-970, Rio de Janeiro, RJ  
E-mail: alfredo@cos.ufrj.br

Diferenças pontuais entre pares de bases de diferentes seqüências alinhadas, são o tipo mais comum de variabilidade genética. Tais diferenças, conhecidas como polimorfismos base única (*single nucleotide polymorphisms* - SNPs), são importantes no estudo da variabilidade das espécies, pois podem provocar alterações funcionais ou fenotípicas, que, por sua vez, podem implicar em consequências evolutivas ou bioquímicas nos indivíduos das espécies. A descoberta de SNPs por algoritmos computacionais é uma prática bastante difundida e, nessa área, dois *scripts* se destacam pelo amplo uso: Polyphred [1] e Polybayes [2].

O Polyphred, analisa diretamente os sinais expressos no seqüenciamento do material genético e detecta SNPs a partir da variação dos sinais de fluorescência dos cromatogramas, procurando por reduções nas regiões do pico do sinal. Se for encontrada uma redução, onde uma segunda base foi detectada, então esse ponto é identificado como potencial heterozigoto. Após o alinhamento das seqüências (*reads*), as bases dessa seção transversal, que inclui *reads* e consensus, são comparadas. O Polybayes analisa as bases geradas a partir da "leitura" dos cromatogramas - feita por *base-calling* [3]. Que nomeia e atribui um valor de qualidade para cada base (*Pred quality score - PQS*) - e utiliza um algoritmo de inferência Bayesiana, que procura por seqüências transversais onde os *reads* alinhados apresentam bases diferentes entre si. O Polybayes considera o número de *reads* e, ainda, a taxa *a priori* de pontos polimórficos, como sendo  $(\frac{1-0.003}{4})$ , ou seja, um SNP para cada 333 pares de bases, dividido pelo número de possíveis diferentes bases - A, T, C ou G - em um ponto. Deve ser notado que, esses dois *scripts*, têm seus resultados influenciados pelo PQS, obtido durante a leitura dos cromatogramas.

Os referidos *scripts* trabalham com diferentes metodologias, sobre diferentes atributos, conduzindo a expectativa que apresentem resultados similares, ao tratar um mesmo conjunto de seqüências, mas, não é incomum fornecerem resultados diferentes, o que produz incerteza na tomada de decisão, quando os resultados são discordantes.

O presente texto apresenta um modelo que se baseia em lógica difusa (*fuzzy logic*) para, a partir dos resultados do Polyphred e do Polybayes, auxiliar na tomada de decisão, no caso em que as informações sejam divergentes e, também, na confirmação de informações coincidentes. Ou seja, utiliza a lógica difusa para dar suporte à decisão, avaliando os resultados gerados por dois diferentes métodos e, ainda, incluindo, explicitamente, o PQS das bases do consenso, como um "valorizador" adicional, que reduz os efeitos específicos de cada um dos *scripts*.

A metodologia aqui apresentada não define nenhum limiar de "corre", no que se refere ao PQS, pois, o modelo de inferência difusa, automaticamente, elimina os pontos de baixa qualidade, não classificando-os como SNPs. Os critérios para a definição das variáveis linguísticas (conjuntos difusos), seus qualificadores e das funções de pertinência (expressões 2, 3 e 4), fundamentaram-se:

1. no índice atribuído pelo Polyphred (*Polyphred score - PPS*), que estabelece seis classes com intervalos *crispas*, variando de 1, que indica um *PPS*  $\leq 49$  e um taxa de verdadeiros positivos de 1%, sendo improvável a existência de SNPs. Até 6, que indica *PPS*  $\geq 99$ , e uma taxa de verdadeiros positivos de 97%, sendo altamente provável a existência de SNPs, e, então, a variável linguística probabilidade foi definida nos termos: improvável (*P<sub>NP</sub>*), pouco provável (*P<sub>M</sub>*), medianamente provável (*P<sub>MP</sub>*), provável (*P<sub>H</sub>*), muito provável (*P<sub>MR</sub>*) e altamente provável (*P<sub>AP</sub>*);

$$\begin{aligned}
 P_{NP}(x) &= \begin{cases} 1 & x \leq 40 \\ \frac{59-40}{59-6} & 40 < x < 60 \\ 0 & x \geq 60 \end{cases} & P_{M}(x) &= \begin{cases} 0 & x \leq 25 \\ \frac{25-1}{25-59} & 25 < x < 59 \\ 1 & x \geq 59 \end{cases} & P_{MP}(x) &= \begin{cases} 0 & x \leq 60 \\ \frac{60-59}{60-91,5} & 59 < x < 91,5 \\ 1 & x \geq 91,5 \end{cases} \\
 P_{H}(x) &= \begin{cases} 0 & x \leq 80 \\ \frac{80-59}{80-99} & 59 < x < 99 \\ 1 & x \geq 99 \end{cases} & P_{P}(x) &= \begin{cases} 0 & x \leq 95,5 \\ \frac{95,5-99}{95,5-100} & 95,5 < x < 100 \\ 1 & x \geq 100 \end{cases} & P_{AP}(x) &= \begin{cases} 0 & x \leq 99 \\ \frac{99-95,5}{99-100} & 95,5 < x < 100 \\ 1 & x \geq 100 \end{cases} \quad (2)
 \end{aligned}$$

2. na qualidade das bases (PQS), que varia entre 4 e 60, separadas, pelo limiar *PQS* = 20, em duas classes de valores *crispas* e, então, a variável linguística qualidade foi definida nos termos: ruim (*Q<sub>R</sub>*), boa (*Q<sub>B</sub>*) e ótima (*Q<sub>O</sub>*).

$$Q_R(x) = \begin{cases} 1 & x \leq 30 \\ \frac{30-20}{30-50} & 20 < x < 50 \\ 0 & x \geq 50 \end{cases} \quad Q_B(x) = \begin{cases} 0 & x \leq 20 \\ \frac{20-10}{20-50} & 20 < x < 50 \\ 1 & x \geq 50 \end{cases} \quad Q_O(x) = \begin{cases} 0 & x \leq 40 \\ \frac{40-10}{40-50} & 40 < x < 50 \\ 1 & x \geq 50 \end{cases} \quad (3)$$

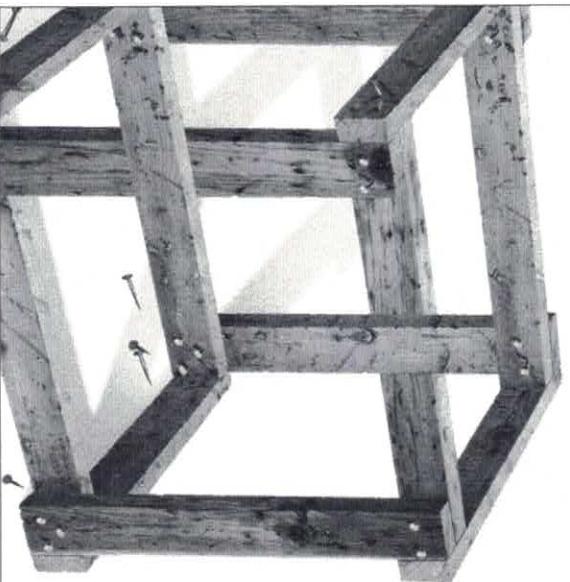
Assim, no modelo de inferência aqui proposto, os valores discretos de entrada - os PPSs, encontrado pelo Polyphred e pelo seu equivalente no Polybayes, e o PQS - têm seus graus de pertinência estabelecidos pelas expressões 2, 3 e 4, que "disparam" regras difusas, cujo resultado é discretizado pelo método do "Centro do Máximo" (*Middle-of-Maxima* MoM), visto que esse considera a ocorrência de múltiplos disparos de regras para uma mesma saída, "valorizando" essa saída. Desse modo, como resultado, determina-se um novo valor, mais apurado, indicativo da existência de polimorfismo, para cada SNP anteriormente identificado, onde foram considerados os valores iniciais dos PPSs e da PQS no ponto.

**Palavras-chave:** Suporte à decisão com inferência difusa, Polimorfismo e Polimorfismo de base única.

### Referências

- [1] Nickerson, D. A., Tobe, V. O. and Taylor, S. L.. PolyPhred: automating the detection and genotyping of single nucleotide substitutions using fluorescence-based resequencing. *Nucleic Acids Research*, 25 (14): 2745-2751, 1997.
- [2] Marth, G. T., Korf, I., Yandell, M. D., Teh, R. T., Gu, Z., Zakeri, H., Stuzziel, N. O., Hillier, L., Kwock, P. Y. and Gish, W. R.. A general approach to single-nucleotide polymorphism discovery. *Nature Genetics*, 23 (4): 452-456, 1999.
- [3] Ewing, B., Hillier, L., Wendel, M. C. and Green, P.. Basecalling of automated sequencer traces using Phred (I). *Genome Research*, 8 175-185, 1998.

**Sessão Técnica:  
Melhores Trabalhos  
Selecionados**



## RESUMOS

# Laboratório Nacional de Modelagem Computacional

13 e 14 de Janeiro de 2009

Petrópolis - RJ

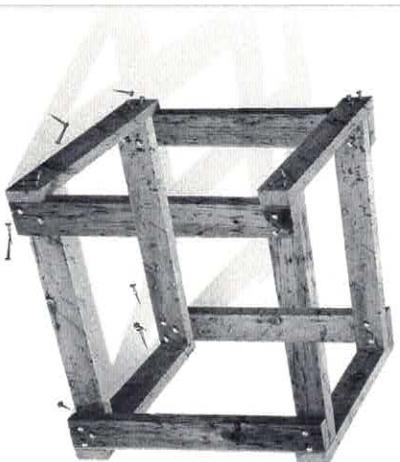
II ENCONTRO ACADÉMICO  
do Laboratório Nacional de Computação Científica

MODELAGEM COMPUTACIONAL

II Encontro Acadêmico de Modelagem Computacional  
do Laboratório Nacional de Computação Científica  
IIEAMC-LNCC/MCT

Petrópolis, Rio de Janeiro, Brasil  
13 – 14 de Janeiro de 2008

# RESUMOS



Comitê Organizador  
Priscila V. Z. Capriles Góliatt  
Jonas Joacir Radtke  
Síclia Ferreira Júdice  
Raphael T. R. de Oliveira  
Raquel Lopes Costa  
Diego Augusto T. Q. Leite

Comitê Científico  
Laurent Emmanuel Dardenne  
Abimael F. Dourado Loula  
Hélio José Corrêa Barbosa  
Jauvane C. de Oliveira  
Raúl Antonino Feijóo  
Sandra Mara C. Malta



## Programação

### 13 de Janeiro de 2008 – Auditório A

| HORÁRIO       | EVENTO  |
|---------------|---|
| 09:00 - 10:00 | P1 – Palestra de Abertura<br>Eugenius Kashurewicz (FINEP)   |
| 10:00 - 10:15 | CO1 – Modelagem Multiescalas - Técnica de Homogeneização<br>Riedson Baptista (LNCC)   |
| 10:15 - 10:30 | CO2 – Dimensão Dinâmica e Fractalidade<br>Marcelo Miranda Barros (LNCC)   |
| 10:30 - 10:50 | ST-P – Apresentação de Pôsteres   |
| 11:00 - 11:30 | P2 – Modelagem Computacional e Verificações Experimentais em Dinâmicas das Estruturas<br>Flávio de Souza Barbosa (UFJF)   |
| 11:30 - 11:45 | CO3 – A Cellular Automata Framework for Real Time Fluid Animation<br>Sicilia Ferreira Ponse Pasini Judge (LNCC)   |
| 11:45 - 12:00 | CO4 – Evolução Diferencial para Otimização Restrita<br>Eduardo Kremser da Silva (LNCC)  |
| 12:00 - 12:30 | P3 – Jogos Educativos e Inovadores<br>Túlio Soria (UNESP)   |
| 12:30 - 13:30 | Almoço  |
| 13:30 - 14:00 | P4 – Criação e Uso de Bases de Dados Secundárias<br>José Miguel Ortega (UFMG)   |
| 14:00 - 14:15 | CO5 – The Importance of Different Temperatures and Electrostatic Treatments on Molecular Dynamics Simulations<br>Priscila Vanessa Zabata Capriles Goliatti (LNCC) |
|               | ST-CO5 – Inferência Difusa como Suporte à Descoberta de Possíveis SNPs em Sequências de cDNA<br>Wagner Arboix (EMBRAPA)   |

### 13 de Janeiro de 2008 – Auditório A

| HORÁRIO       | EVENTO  |
|---------------|---|
| 14:15 - 14:30 | CO6 – Por que Predadores não Têm Efeitos Positivos sobre Presas?<br>José Carlos Lisboa Recaey Eiras (LNCC)  |
| 14:30 - 14:45 | CO7 – A Multidisciplinaridade da Computação Quântica - Desenvolvimento e Perspectivas<br>Amanda Castro Oliveira (LNCC)  |
| 14:45 - 15:00 | CO8 – Assimilação de Dados de Unidade do Solo Aplicado ao Modelo Hidrológico NOAH<br>Cláudia Adam Ramos (LNCC)  |
| 15:00 - 15:30 | P5 – Modelagem Integrada da Atmosfera-Biosfera-Hidrosfera<br>Marcos Heil Costa (UFV)  |
| 15:30 - 15:50 | ST-P – Apresentação de Pôsteres   |
| 16:00 - 16:15 | ST-CO1 – Processo de Busca do Parâmetro de Regularização Ótimo em um Problema de Restauração de Imagens<br>Dalmo Stutz (UFRJ/IPRJ)  |
| 16:15 - 16:30 | ST-CO2 – A Performance Evaluation of a Parallel Implementation of the Inexact Jacobian-Free Newton-Krylov Method Using the PETSc Numerical Framework<br>Rafael Santos Coelho (UFES) |
| 16:30 - 16:45 | ST-CO3 – A Nonlinear Subgrid Discontinuous Galerkin Method for Transport Problems<br>Natalia Andrade (LNCC)   |
| 16:45 - 17:00 | ST-CO4 – Modeling Heat Treatment of Steels by the Colorimeter Method<br>Cecília Grisell Arone (KB Engineering S.R.L.)   |
| 17:00 - 17:15 | ST-CO5 – Inferência Difusa como Suporte à Descoberta de Possíveis SNPs em Sequências de cDNA<br>Wagner Arboix (EMBRAPA)   |

P – Palestra

CO – Comunicação Oral

ST-P – Sessão Técnica-Pôster

P – Palestra

CO – Comunicação Oral

ST-P – Sessão Técnica-Pôster

CO – Comunicação Oral

ST-P – Sessão Técnica-Pôster

## Sumário

|  |    |
|--|----|
| CONTROLE DE VELOCIDADE DE UM MOTOR CC UTILIZANDO UM MICROCONTROLADOR PIC COM PROGRAMAÇÃO EM ASSEMBLY   | 33 |
| IMPACTO DA QUEBRA DE ONDAS OCEÂNICAS NA ESTRUTURA DA CAMADA LIMITE PLANETÁRIA  | 34 |
| ALGORITMOS DE BIOINFORMÁTICA PARA DETECÇÃO DE NULLOMERS NO TRANSCRIPTÔMA HUMANO  | 35 |
| BIFURCATIONS AND CHAOTIC DYNAMICS ANALYSIS OF THE ELASTIC PENDULUM   | 37 |
| SOLUÇÃO ANALÍTICA DAS EQUAÇÕES DA CINÉTICA PONTUAL PARA VARIAÇÃO LINEAR DA REATIVIDADE DURANTE A PARTIDA DE UM REATOR NUCLEAR.                     | 39 |
| MÉTODO ANALÍTICO DE IDENTIFICAÇÃO DE SISTEMAS MULTIVARIÁVEIS NO DOMÍNIO DA FREQUÊNCIA  | 41 |
| MODELOS DE PROGRAMAÇÃO LINEAR INTEIRA PARA REDES   | 43 |
| UMA ARQUITETURA DE MONITORAMENTO AMBIENTAL   | 45 |
| CONSTRUÇÃO DE BIBLIOTECAS DE FRAGMENTOS PARA A PREDIÇÃO DE ESTRUTURAS DE PROTEÍNAS   | 47 |
| IMPLEMENTAÇÃO DA ANÁLISE DE BIOLOGIA DE SISTEMAS DO FUNGO CAUSADOR DA VASSOURA DE BRUXA DO CACAUERIRO  | 49 |
| APLICAÇÃO DE SISTEMAS BASEADOS EM REGRAS FUZZY PARA O ROTEAMENTO EM REDES ÓPTICAS  | 51 |
| <b>A PERFORMANCE EVALUATION OF A PARALLEL IMPLEMENTATION OF THE INEXACT JACOBIAN-FREE NEWTON-KRYLOV METHOD USING THE PETSC NUMERICAL FRAMEWORK</b> | 51 |
| <b>A NONLINEAR SUBGRID DISCONTINUOUS GALERKIN METHOD FOR TRANSPORT PROBLEMS</b>  | 17 |
| <b>MODELING HEAT TREATMENT OF STEELS BY THE CALORIMETER METHOD</b>   | 18 |
| <b>INFERÊNCIA DIFUSA COMO SUPORTE À DESCOPERTA DE POSSIVEIS SNPs EM SEQUENCIAS DE cDNA</b>   | 19 |
| SEQUENCE ANALYSIS OF BOVINE PAPILLOMAVIRUS FOR THE ESTABLISHMENT OF DEGENERATE AND TYPE-SPECIFIC PRIMERS   | 22 |
| THE ADAPTIVE MESH REFINEMENT AND COARSENING (AMR/C) SCHEME IN THE LIBMESH  | 23 |
| MOLECULAR DYNAMICS SIMULATIONS OF CALMODULIN: A COMPARATIVE STUDY OF REACTION FIELD AND PARTICLE-MESH EWALD ELETROSTATIC TREATMENTS                | 24 |
| HIBERNATE: UM FRAMEWORK DE MAPEAMENTO OBJETO RELACIONAL  | 25 |
| THE USE OF NEURAL NETWORKS IN CONTROL SYSTEMS FOR DETECTION AND FAILURES IN SENSORS  | 27 |
| MHOLine: PORTAL PARA MODELAGEM COMPARATIVA EM GRANDE ESCALA USANDO WORKFLOW  | 28 |
| DETERMINAÇÃO DO NÚMERO REPRODUTIVO BÁSICO EM MODELOS NÃO AUTÔNOMOS   | 29 |
| NOVOS MÉTODOS DE ELEMENTOS FINITOS ENRIQUECIDOS E ESTABILIZADOS APLICADOS A EQUAÇÃO DE REAÇÃO-DIFUSÃO  | 31 |
| <b>LISTA DE AUTORES</b>  | 53 |