

PELICAN: FERRAMENTA PARA INFERÊNCIA DE ANOTAÇÃO DE CONSENSO EM GENOMAS DE FAGOS

Pedro Rossi de Andrade Franco

**Guilherme Wenceslau de Lima Cardoso, Guilhermo Uceda Campos,
Fernando Pacheco Nobre Rossi**

Prof. Dr. João Carlos Setubal

Universidade de São Paulo

pedro.andrade.franco@usp.br

Objetivos

A anotação de genomas de bacteriófagos (fagos), vírus que infectam bactérias, é uma etapa importante para a compreensão de sua biologia. Porém, as principais ferramentas computacionais de anotação frequentemente produzem resultados divergentes entre si. Nesse contexto, o presente projeto tem como objetivo principal desenvolver uma ferramenta capaz de gerar automaticamente uma anotação consenso para genomas de fagos. Objetivos específicos da ferramenta, intitulada PELICAN, são: agregar e comparar previsões de algumas ferramentas existentes de anotação; avaliar os genes identificados por cada uma; e gerar uma previsão final de forma unificada e mais acurada, baseada no consenso entre os diferentes métodos utilizados.

Métodos e Procedimentos

O pipeline de análise do PELICAN inicia com um genoma de bacteriófago em formato FASTA dado pelo usuário. Quatro ferramentas de anotação são então executadas em paralelo: Phanotate, PROKKA-virus, Prodigal e GLIMMER. O Consenso I é identificar os genes

previstos por pelo menos duas das ferramentas empregadas. Os genes restantes, ou seja, aqueles que não entraram no primeiro consenso, são submetidos a uma busca por similaridade de sequência, por meio de BlastP, contra a base de dados de proteínas de fagos PHROGS. Os resultados com *hits* significativos formam o Consenso II [1]. Finalmente, os genes que ainda permanecem sem classificação são analisados por um modelo de *deep learning* (AutoEncoder) baseado em redes neurais convolucionais. Este modelo é treinado para reconhecer características de genes de fagos, e classifica as sequências restantes, gerando o Consenso III. A anotação final é a união dos três conjuntos de consenso, conforme exemplificado na Figura 1.




Figura 1: Consenso do genoma do bacteriófago NC_048638.1

A performance da ferramenta foi testada preliminarmente usando 20 genomas de fagos do projeto Sea-Phages [2], comparando resultados do PELICAN com os resultados da anotação manual e de outras ferramentas.

Resultados

Ao ser aplicada aos testes, a ferramenta PELICAN predisse um total de 2.467 genes, um número superior aos genes previstos por ferramentas como PROKKA-virus (2.188), PHAROKKA (2.414), GLIMMER (2.127). Em relação à anotação manual, PELICAN alcançou uma média de cobertura de 97,93% dos genes anotados. Este resultado é maior que o obtido pelo PROKKA-virus (94,19%), pelo PHAROKKA (81,04%) e pelo GLIMMER (82,71%), vide a Figura 2.




Figura 2: Distribuição da cobertura dos genomas por preditor

Além disso, PELICAN apresentou a menor quantidade de genes perdidos (genes não identificados pela ferramenta em relação aos genes identificados por anotação manual), com apenas 62 genes perdidos enquanto PROKKA-virus, GLIMMER e PHAROKKA perderam 182, 399 e 427, respectivamente.

Conclusões

A ferramenta PELICAN se mostrou robusta e eficaz na anotação dos genomas dos fagos testados até agora. A estratégia de combinar o consenso entre anotadores, a homologia com bancos de dados e o modelo de *deep learning* permitiu alcançar uma cobertura gênica maior e um menor número genes perdidos em relação com as ferramentas padrão de anotação. Os resultados preliminares sugerem que PELICAN consegue automatizar o processo de anotação com alta precisão, além de refinar anotações existentes, aproximando-se da qualidade da curadoria manual. Os próximos passos incluem a validação da ferramenta com dados de transcriptômica e com genomas de fagos recém-isolados pelo grupo de pesquisa.

Os colaboradores declararam não haver conflito de interesses. Rossi concebeu a ferramenta. Franco, Campos e Rossi construíram a ferramenta. Rossi, Cardoso, Campos e Rossi testaram a ferramenta. Todos os colaboradores aprovaram a versão final do resumo.

Agradecimentos

Agradeço à Prof.^a Dr.^a Aline Maria da Silva (*in memoriam*) pela orientação inicial no projeto e ao Prof. Dr. João Carlos Setubal por aceitar me orientar após a perda da Prof.^a Aline. Agradeço também aos colegas de projeto, de laboratório e à Prof.^a Dr.^a Regina Baldini por todo o apoio. Por fim, agradeço ao CNPq pela bolsa de ITI-A.

Referências

- [1] TURNER, Dann et al. Phage annotation guide: guidelines for assembly and high-quality annotation. **Phage**, v. 2, n. 4, p. 170-182, 2021.
- [2] RUSSELL, Daniel A.; HATFULL, Graham F. PhagesDB: the actinobacteriophage database. **Bioinformatics**, v. 33, n. 5, p. 784-786, 2017.