

Controle de qualidade de SNPs e de Amostras

Prof. Dr. Fernando Baldi

UNESP-FCAV

Marcos Vinicius Barbosa da Silva

EMBRAPA GADO DE LEITE

Programa do dia

- ✓ Controle de Qualidade com painéis de alta densidade
- ✓ Estudos de associação ampla com um único marcador
- ✓ Estudos de associação ampla utilizando haplótipos
- ✓ Abordagem de genes idênticos por descendência (IBD)
- ✓ Associação com marcadores múltiplos
- ✓ Problemas nos estudos de associação ampla do genoma
- ✓ Métodos de seleção de SNPs para estudos de associação ampla
- ✓ Softwares para estudos de associação ampla






Controle de Qualidade em GWAS


- As tecnologias de genotipagem em larga escala com painéis de alta densidade são muito precisas, mas não são perfeitas
- Alta automatização
- Mesmo com uma precisão de 99,9%, uma análise do genoma de 2.000 indivíduos para 500.000 marcadores da **1.000.000 erros de genotipagem!**
- Erros de genotipagem podem aumentar o número de resultados falso-positivos (falsos SNP significativos)



Por que o controle de qualidade dos dados é importante?



Ger MI FS I, Affymetrix 500k array set, SNPs on chip: 493,840



Ger MI FS I, Affymetrix 500k array set, SNPs on chip: 493,840
SNPs passing standard quality control: 270,701




Controle de Qualidade em GWAS

- A qualidade dos dados é importante e os dados genômicos devem ser verificados cuidadosamente:
 - ✓ Padrões incomuns de dados faltantes
 - ✓ Problemas de análises laboratoriais
 - ✓ Problemas nas amostras e chips (efeito de lote)
- Intensidade dos “spots” e atribuição dos genótipos
 - ✓ intensidade de sinal do “spot” é convertido em genótipos
- Depois de atribuídos os genótipos, análises intensivas de controle de qualidade precisam são executadas



Controle de Qualidade em GWAS



Controle de Qualidade em GWAS

Passos no controle de qualidade:

- Falta de alelos ou perda de Genótipos
- Alelos em baixa frequência (MAF)
- Marcadores com alelos fixados ou alta proporção de heterozigotos
- Desvios do Equilíbrio de Hardy-Weinberg (H-W)
- Controle a nível de indivíduo
- Estratificação da população

Ziegler et al. (2008)

Dados de genótipos perdidos

- Problemas para inferir o genótipo a partir da intensidade de sinal (“*call rate*”)
- SNPs são de qualidade questionável se a sua genotipagem falhou em muitos indivíduos
- Problemática em análises múltipla (alguns indivíduos tem, outros não)
- Uma solução prática é a imputação de dados

Menor Frequência de um dos alelos (MAF)

- Menor frequência de um dos alelos (MAF): refere-se a frequência na qual o alelo menos comum ocorre em uma determinada população.
 - muito poucas observações sobre esses alelos
- Por causa do baixo poder para detectar uma associação entre o SNP e a característica de interesse, é razoável excluir esses SNPs.
- O critério de filtro normalmente varia com o tamanho da amostra e os valores variam de 1% a 5%.

Equilíbrio de Hardy-Weinberg (HWE)

- Desvio de HWE podem ser devido à endogamia, mutação, estratificação da população, seleção etc.
- Controle de qualidade: desvios aparentes do HWE por causa de uma tendência de atribuir os homocigotos como heterocigotos (excesso de indivíduos heterocigotos). Critério utilizado $p\text{-value} < 10^{-6}$
- Teste de desvios HWE pode ser realizado pelo teste de Pearson ou teste exato de Fisher
 - R “*genetics package*” que implementa ambos os testes de Pearson (*chi-square*) e Fisher

Controle de Qualidade por Amostra

- Excluir indivíduos com menos de 90% dos SNPs genotipados com sucesso (*call rate*)
 - Incluindo os SNPs monomórficos
- **Nível de heterocigose**
 - Um nível muito alto pode ser um indicador de contaminação de DNA. Estimar a média e o desvio padrão da heterocigosidade em todos os indivíduos e excluir todos aqueles fora do intervalo média $\pm SD \cdot 3$.
- **Parentesco entre indivíduos** (*Mendelian error*: $< 1\%$) e Sexo ID
 - Alelos de um indivíduo diferentes dos alelos dos seus pais biológicos
- **Estratificação da população**
 - Diferenças nas frequências alélicas
 - Pode levar a um viés substancial nas análises estatísticas
 - Análise estratificada por localização geográfica ou grupo (*clusters*)

O Bovine HDBeadchip com Genoma de Nelore

- 777.962 SNP disponíveis
- 48 touros Nelore genotipados
- 332.207 SNP foram eliminados
 - 2.959 sem cromossomo definido
 - 7.198 *Baixo Call rate*
 - 16.222 Problemas de cluster
 - 3.379 Excesso de Heterozigotos
 - 1.353 MAF < 0.05
 - 280.229 monomorficos
- 445.755 SNP para análise

Baldi et al. (2012)

Software

- PLINK
<http://zzz.bwh.harvard.edu/plink/>
- SVS Golden Helix
https://www.goldenhelix.com/products/SNP_Variation/index.html
- Pacote R snpStats
<https://www.bioconductor.org/packages/release/bioc/html/snpStats.html>