


MONTAGEM DE GENOMAS DE NOVO E AVALIAÇÃO

GUSTAVO NASCIMENTO, MARIA GABRIELA E KEVIN



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

1.

**FIRST-GENERATION
SEQUENCING**

Sanger

2.

**SECOND-GENERATION
SEQUENCING (NGS)**

Illumina
Pirosequenciamento

3.

**THIRD-GENERATION
SEQUENCING**

PacBio
ONT



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

SECOND-GENERATION SEQUENCING (NGS)

- Conhecido também como Sequenciamento de Alta Performance
- Fragmentos de 50-300 bp
- Custo baixo por bp
- Automático
- Processamento paralelo massivo de fragmentos de DNA
- Sequenciamento em dias

ILLUMINA

PIROSEQUENCIAMENTO

ION TORRENT

ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

THIRD-GENERATION SEQUENCING

- Sequenciamento de fragmentos longos
- Não é preciso fazer PCR da amostra
- ~12kb - ~2Mb
- É necessário pouca amostra
- Baixo - moderado custo por bp
- Sequenciamento em horas


OXFORD NANOPORE

PACIFIC BIOSCIENCES

IBM'S DNA TRANSISTOR


ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

ESTRATEGIAS PARA MONTAGEM COM SHORT READS



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

ESTRATEGIAS PARA MONTAGEM COM SHORT READS



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

PROGRAMAS DE MONTAGEM DE SHORT READS

ABySS

ALLPATHS

Edena


SGA

SHARCGS

SHORTY

ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO


ESTRATEGIAS PARA MONTAGEM COM LONG READS



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

ESTRATEGIAS PARA MONTAGEM COM LONG READS

Figure 2. Comparison of results of independent assembly strategies. (A) Genome assembled with nanopore reads; (B) longest contig assembled with PacBio reads; (C) genome assembled with Illumina reads. Plots were obtained by using Bandage on the "assembly_graph.gfa" output file from SPAdes or the "contig.gfa" output file from Canu. Connections between contigs represent overlaps between contig ends.



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

PROGRAMAS DE MONTAGEM DE LONG READS

COM CORREÇÃO DE ERROS

CANU

FALCON

HGAP

SEM CORREÇÃO DE ERROS

HINGE

MINIMAP

TULIP

ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

PROGRAMAS DE MONTAGEM DE LONG READS

MAPEAMENTO

BWA-MEM

minialign/minimap

BBMap/BBTools

CORREÇÃO DE ERROS

Frame-Pro

MINIMAP

TULIP

ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

PROGRAMAS DE MONTAGEM DE LONG READS

POLIMENTO DE SEQUENCIAS


Nanopolish

Racon

pilon

ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

RECOMENDAÇÃO DE PIPELINE



ESTRATÉGIAS PARA A MONTAGEM DE GENOMAS DE NOVO

ESTRATEGIAS PARA MONTAGEM HIBRIDAS

- Compensa pelos problemas de casa estrategia
- Illumina + PacBio
- Útil para genomas de plantas poliploide
- Conseguir maior sequencias e contiguidade de scaffolds.

Unicycler

MaSuRCA

BIOINFORMÁTICA

DNA

RNA

Proteína



Esse dados são armazenados em formatos digitais

Tipos de arquivos gerados

FASTA

- Descrito no final dos anos 80;
- Com o tempo evoluiu por consenso;
- Difícil de lidar com linhas longas sem quebra de linha;
- Formato utilizado em genomas de referência.

Arquivo FASTA

```
>NG_008679.1:5001-38170 Homo sapiens paired box 6 (PAX6)
ACCCTCTTTTCTTATCATTGACATTTAAACTCTGGGGCAGGTCCTCGCGTAGAACGCGGGCTGTCAGATCT
GCCACTTCCCCTGCCGAGCGGCGGTGAGAAGTGTGGGAACCGGCGCTGCCAGGCTCACCTGCCTCCCCGC
CCTCCGCTCCCAGGTAACCGCCCCGGGCTCCGGCCCCGGCCCCGGCTCGGGGGCCCGCGGGGGCCTCTCCGCTG
CCAGCGACTGCTGTCCCCAAATCAAAGCCCCCAAGTGGCCCCGGGGCTTGATTTTTTGCTTTTAAAAG
GAGGCATACAAAGATGGAAGCGAGTTACTGAGGGAGGGATAGGAAGGGGGGTGGAGGAGGGACTTGTCCTT
TGCCGAGTGTGCTCTTCTGCAAAAAGTAGCAAAAATGTTCCACTCCTAAGAGTGGACTTCCAGTCCGGCCCT
GAGCTGGGAGTAGGGGGCGGGAGTCTGCTGCTGCTGTCTGCTAAAGCCACTCGCGACCGCGAAAAATGCA
GGAGGTGGGGACGCACTTTGCATCCAGACCTCCTCTGCATCGCAGTTCACGACATCCACGCTTGGGAAAG
TCCGTACCCGCGCCTGGAGCGCTTAAAGACACCCTGCCGCGGGTCGGGGCGAGGTGCAGCAGAAGTTCCC
GCGGTTGCAAAGTGCAGATGGCTGGACCGCAACAAAGTCTAGAGATGGGGTTCGTTTCTCAGAAAGACGC
```

FASTQ

- Contém sequências + pontuações de qualidade;
- Formato de dados perpetuado e amplamente aceito;
- Possui variantes:

1. **Sanger standard: fastq-sanger;**
2. **Solexa/Illumina: fastq-solexa;**
3. **Illumina 1.3+: fastq-illumina**

BED

- Representa regiões genômicas de forma simples e flexível;
- Contém informações sobre as anotações do dado genômico, onde inicia e onde termina alguma característica em um segmento de DNA;
- Usado para delimitar regiões de interesse no genoma.

VCF

- Armazena as informações das variantes genéticas identificadas em um organismo;
- Variantes SNPs;
- Versionado;
- Compara ao genoma de referência.

ARQUIVO VCF

```
##fileformat=VCFv4.2
##fileDate=20090805
##source=myImputationProgramV3.1
##reference=file:///seq/references/1000GenomesPilot-NCBI36.fasta
##contig=<ID=20,length=62435964,assembly=B36,md5=f126cdf8a6e0c7f379d618ff66beb2da,species="Homo sapiens",taxonomy=x>
##phasing=partial
##INFO=<ID=NS,Number=1,Type=Integer,Description="Number of Samples With Data">
##INFO=<ID=DP,Number=1,Type=Integer,Description="Total Depth">
##INFO=<ID=AF,Number=A,Type=Float,Description="Allele Frequency">
##INFO=<ID=AA,Number=1,Type=String,Description="Ancestral Allele">
##INFO=<ID=DB,Number=0,Type=Flag,Description="dbSNP membership, build 129">
##INFO=<ID=H2,Number=0,Type=Flag,Description="HapMap2 membership">
##FILTER=<ID=q10,Description="Quality below 10">
##FILTER=<ID=s50,Description="Less than 50% of samples have data">
##FORMAT=<ID=GT,Number=1,Type=String,Description="Genotype">
##FORMAT=<ID=GQ,Number=1,Type=Integer,Description="Genotype Quality">
##FORMAT=<ID=DP,Number=1,Type=Integer,Description="Read Depth">
##FORMAT=<ID=HQ,Number=2,Type=Integer,Description="Haplotype Quality">
#CHROM POS ID REF ALT QUAL FILTER INFO FORMAT NA00001
20 14370 rs6054257 G A 29 PASS NS=3;DP=14;AF=0.5;DB;H2 GT:GQ:DP:HQ 0|0:48:1:51,51
20 17330 . T A 3 q10 NS=3;DP=11;AF=0.017 GT:GQ:DP:HQ 0|0:49:3:58,50
20 1110696 rs6040355 A G,T 67 PASS NS=2;DP=10;AF=0.333,0.667;AA=T;DB GT:GQ:DP:HQ 1|2:21:6:23,27
20 1230237 . T . 47 PASS NS=3;DP=13;AA=T GT:GQ:DP:HQ 0|0:54:7:56,60
20 1234567 microsat1 GTC G,GTCT 50 PASS NS=3;DP=9;AA=G GT:GQ:DP 0/1:35:4
```

(1) Cabeçalho de metadados, (2) Cabeçalho e (3) Linhas contendo os dados e suas devidas anotações.

FAST5

Oxford Nanopore

- Hierárquico;
- Formato de dados com um esquema específico;
- Armazenar grandes dados;
- Biblioteca exclusiva;
- Pode causar lentidão durante a análise.

SLOW5

Oxford Nanopore

- Criado a parti do FAST5;
- Codifica todas as informações encontradas no FAST5;
- Não depende de biblioteca única.

TIPOS DE DADOS PARA ALINHAMENTO

SAM

Sequence Alignment Map

- Realiza mapeamento de leitura eficiente contra grandes sequências de referência;
- Armazena alinhamentos de leitura para uma sequência de referência;
- Escala conjuntos de alinhamento de 1.011 ou mais pb.
- Uma seção de cabeçalho e uma seção de alinhamento.

BAM


- Formato complementar Binary Alignment/Map;
- Representação binária do SAM e mantém exatamente as mesmas informações;
- O objetivo é reduzir o espaço que ocupa no disco.

BLOW5

Oxford Nanopore

- Formato SLOW5 codificado em formato binário;
- Análogo ao formato SAM/BAM para armazenar alinhamentos de sequência;
- Alocação de espaço mais simples e à redução da redundância de metadados.

Após o mapeamento dos reads (FASTQ) contra o genoma de referência (FASTA), e identificação das regiões específicas (BED) no mapeamento (SAM/BAM), é possível obter as variantes nestas regiões (VCF).





GENOME ASSEMBLY VALIDATION

THEMES

- **Continuity**
- **Structural accuracy**
- **REAPR**
- **Base accuracy**
- **Functional completeness**
- **BUSCO**
- **Chromosome status**





CONTINUITY

Quality category	Metric	Finished	VGP-2020	VGP-2016	B10k-2014
Notation	<i>x.y.P.Q.C</i>	c.c.Pc.Q60.C100	7.c.P6.Q50.C95	6.7.P5.Q40.C90	4.5.Q30
Continuity	Contig NG50 (<i>x</i>)	= Chr. NG50	>10 Mb	>1 Mb	>10 kb
	Scaffolds NG50 (<i>y</i>)	= Chr. NG50	= Chr. NG50	>10 Mb	>100 kb
	Gaps per Gb	No gaps	<200	<1,000	<10,000

BLOBTOOLS

BlobTools is a bioinformatics tool used for the visualization, quality control, and taxonomic partitioning of genome datasets. It can assist in primary partitioning of data, leading to improved assemblies, and screening of final assemblies for potential contaminants




STRUCTURAL ACCURACY

Quality category	Metric	Finished	VGP-2020	VGP-2016
Structural accuracy	Reliable blocks	= Chr. NG50	>10 Mb	>1 Mb
	False duplications	0%	<1%	<5%
	Curation	Conflicts resolved	Manual	Manual

REAPR

REAPR is a tool that evaluates the accuracy of a genome assembly using mapped paired end reads, without the use of a reference genome for comparison



BASE ACCURACY

Quality category	Metric	Finished	VGP-2020	VGP-2016
Base accuracy	Base pair QV (Q)	>60	>50	>40
	<i>k</i> -mer completeness	100% complete	>95%	>90%

FUNCTIONAL COMPLETENESS



Quality category	Metric	Finished	VGP-2020	VGP-2016	B10k-2014
Functional completeness	Genes	>98% complete	>95% complete	>90%	>80%
	Transcript mappability	>98%	>90%	>80%	>70%




BUSCO

BUSCO is a bioinformatics tool used to assess the quality of genome annotations and the completeness of genome assemblies. BUSCO provides quantitative measures for assessing gene completeness in terms of expected genes found in a dataset.

CHROMOSOME STATUS



Quality category	Metric	Finished	VGP-2020	VGP-2016
Chromosome status	Assigned (C)	>100%	>95%	>90%
	Sex chromosomes	Right order, no gaps	Localized homo pairs	At least one shared (for example, X or Z)
	Organelles (for example, MT)	One complete allele	One complete allele	Fragmented



Rhie, A., McCarthy, S.A., Fedrigo, O. et al. Towards complete and error-free genome assemblies of all vertebrate species. Nature 592, 737–746 (2021). <https://doi.org/10.1038/s41586-021-03451-0>