


# 変異検出用ソフトウェア Sentieon を使用した Joint Genotyping

フィルジェン株式会社 バイオインフォマティクス部  
(support@filgen.jp)


## 一次解析



ATGGTGTGCG  
GTGTCCAGCG  
CTTCGCCAGCG


- ・ベースコール

## 二次解析




- ・リードマッピング
- ・バリエントコール

## 三次解析



- ・アノテーション付け
  - ・フィルタリング
  - ・トリオ解析
  - ・ビジュアライゼーション
  - ・レポート作成
- など


## 一次解析



ATGGTGTGCG  
GTGTCCAGCG  
CTTCGCCAGCG


・ベースコール

## 二次解析




- ・リードマッピング
- ・バリエントコール

## 三次解析



- ・アノテーション付け
  - ・フィルタリング
  - ・トリオ解析
  - ・ビジュアライゼーション
  - ・レポート作成
- など

## 二次解析




- ・ゲノム上に膨大な量のリードをマッピング
- ・シーケンスエラー等も考慮しながら、変異サイトを検出

→大量の計算リソースを必要とするプロセス

- ・リードマッピング
- ・バリアントコール

## 二次解析



- ・リードマッピング
- ・バリアントコール

### 二次解析用のソフトウェア


- ・Illumina DRAGEN
  - ・GATK
  - ・NVIDIA Parabricks
  - ・Sentieon
- など

オープンソースのものから商用のものまで様々

## Sentieonを使うメリット


- ・二次解析のゴールドスタンダードであるGATKと同じ数学モデルを使用しつつ、アルゴリズムを見直すことで高速化を実現
- ・一般的なCPUベースのシステムで動作
- ・さまざまな解析用のサンプルスクリプトの提供
- ・ロングリードやハイブリッドアセンブリに対応したパイプラインも提供

# SentieonとGATKの比較



- ・ BAMファイルからのVCFファイル作成において、SentieonはGATKに比べて30倍～50倍程度（エクソーム）、20倍～30倍程度（全ゲノム）の高速化を実現 (Weber et al., 2016)
- ・ FASTQファイルからVCFファイル作成の場合は、10倍程度の高速を実現

# SentieonとGATKの比較



- ・SentieonとGATKでコールされたバリアントを比較した結果、99.8%のバリアントが共通してコールされていた。

誤差は、GATKのダウンサンプリング（※）や丸め誤差に起因するものであった（Weber et al., 2016）。

※GATKでは、高カバレッジ領域においてリードのダウンサンプリングを行うため、解析ごとに結果がばらつく

## Sentieon DNaseq

- ・生殖細胞系列変異の検出
- ・GATKと同じ結果だが、より高速

## Sentieon DNAscope

- ・生殖細胞系列変異の検出
- ・アセンブリアルゴリズムの改良と機械学習による精度向上

## Sentieon TNseq

- ・体細胞系列変異の検出
- ・Mutect/Mutect2と同じ結果だが、より高速

## Sentieon TNscope

- ・体細胞系列変異の検出
- ・SNV, INDEL, SVを包括的に検出

## Sentieon DNaseq


- ・生殖細胞系列変異の検出
- ・GATKと同じ結果だが、より高速

## Sentieon DNAscope

- ・生殖細胞系列変異の検出
- ・アセンブリアルゴリズムの改良と機械学習による精度向上


Illumina社、Complete Genomics社、PacBio社、Ultima Genomics社、Element Biosciences社、Oxford Nanopore社等、さまざまなプラットフォームに特有のモデルを使用し、精度を向上

# DNAseq vs DNAscope



GA4GHが既定するゲノム上のさまざまな領域 (Krusche, P. et al., 2019)において、  
DNAscopeはDNAseqの変異検出性能を上回る (Freed, P. et al., 2022)

# DNaseq vs DNAscope



特に低カバレッジ領域において、DNAscopeはDNaseqの変異検出性能を上回る (Freed, P. et al., 2022)

## Sentieon DNAscope LongRead

- ・生殖細胞系列変異の検出
- ・アセンブリアルゴリズムの改良と機械学習による精度向上
- ・ロングリードに対応

## Sentieon DNAscope Hybrid

- ・生殖細胞系列変異の検出
- ・アセンブリアルゴリズムの改良と機械学習による精度向上
- ・ハイブリッドアセンブリに対応

# その他のパイプライン

## Pipeline Functions


Pipelines	DNAscope (short reads)	Pangenome	DNAscope LongRead	DNAscope Hybird	DNAseq	TNsphere (somatic)	TNseq (somatic)
Alignment	✓	✓	✓	✓	✓	✓	✓
SNP/Indel	✓	✓	✓	✓	✓	✓	✓
SV	✓	✓	✓	✓		✓	
CNV	✓	✓		✓			
Segdup Genes	✓	✓		✓			
UMI Process						✓	
Matching GATK					✓		✓

# 今回使用するパイプライン

## Pipeline Functions


Pipelines	DNAscope (short reads)	Pangenome	DNAscope LongRead	DNAscope Hybird	DNAseq	TNsphere (somatic)	TNseq (somatic)
Alignment	✓	✓	✓	✓	✓	✓	✓
SNP/Indel	✓	✓	✓	✓	✓	✓	✓
SV	✓	✓	✓	✓		✓	
CNV	✓	✓		✓			
Segdup Genes	✓	✓		✓			
UMI Process						✓	
Matching GATK					✓		✓

# 一般的なDNAseqパイプライン



# Joint Genotyping用のパイプライン

DNAseqを使用する場合



# DNAseqを使用したJoint Calling①

## マッピングとソート


```
sentieon bwa mem -R '@RG¥tID:GROUP_NAME¥tSM:SAMPLE_NAME¥tPL:PLATFORM' -t  
NUMBER_THREADS REFERENCE SAMPLE [SAMPLE2] || echo -n 'error' )  
| sentieon util sort -r REFERENCE -o SORTED_BAM -t NUMBER_THREADS --sam2bam -i -
```

sentieon bwa mem: マッピングを実行するコマンド

- R: BAMファイルのヘッダーを入力
- tID: リードに固有のID
- tSM: サンプルに固有のID
- tPL: プラットフォーム名
- t: スレッド数

Sentieon util sort: BAMファイルのソートを実行するコマンド

- r: リファレンス配列の場所／名前
- o: 出力ファイル名
- t: スレッド数



# DNAseqを使用したJoint Calling②

## 重複リードの除去


```
sentieon driver -t NUMBER_THREADS -i SORTED_BAM  
  --algo LocusCollector --fun score_info SCORE.gz  
sentieon driver -t NUMBER_THREADS -i SORTED_BAM  
  --algo Dedup [--rmdup] --score_info SCORE.gz  
  --metrics DEDUP_METRIC_TXT DEDUPED_BAM
```

sentieon driver: パイプラインを実行するための主なコマンド

-t: スレッド数  
-i: 入力ファイル

--algo LocusCollector: 重複リード除去のために必要なリードの情報を集計  
--fun score\_info: スコア関数 (score\_info) の指定

--algo Dedup: 重複リードにフラグを付ける  
--rmdup: フラグが付いたリードの除去  
--score\_info: LocusCollectorの出力  
--metrics: 重複リード除去メトリクスの保存場所



# DNAseqを使用したJoint Calling③


BQSR

```
sentieon driver -t NUMBER_THREADS -r REFERENCE  
-i DEDUPED_BAM --algo QualCal [-k KNOWN_SITES] RECAL_DATA.TABLE
```

sentieon driver: パイプラインを実行するための主なコマンド

- t: スレッド数
- i: 入力ファイル
- r: リファレンス配列の場所／名前

--algo QualCal: キャリブレーション用のテーブルを作成  
-k: 既知のバリアント情報 (.vcf)




# DNAseqを使用したJoint Calling④

## gVCFファイルの作成

```
sentieon driver -r REFERENCE -t NUMBER_THREADS -i DEDUPED_BAM -q RECAL_DATA_TABLE  
--algo Haplotype --emit_mode gvcf VARIANT_GVCF
```

sentieon driver: パイプラインを実行するための主なコマンド

- t: スレッド数
- r: リファレンス配列の場所／名前
- q: キャリブレーション用テーブル
- algo Haplotype: バリアントコールのためのアルゴリズム
- emit mode: 出力するバリアントの指定 (variant, confident, all, gvcf)



# DNAseqを使用したJoint Calling⑤

## Joint Calling


```
sentieon driver -r REFERENCE --algo GVCFtyper -v s1_VARIANT_GVCF -v s2_VARIANT_GVCF  
-v s3_VARIANT_GVCF VARIANT_VCF
```

sentieon driver: パイプラインを実行するための主なコマンド


-r: リファレンス配列の場所／名前

--algo GVCFtyper: バリアントコールのためのアルゴリズム

-v: 入力ファイル



# DNAscopeを使用した場合のパイプライン



BQSRは不要  
(未処理のデータで学習しているため)

# DNAscopeを使用したJoint Calling①

## マッピングとソート

```
sentieon bwa mem -R '@RG¥tID:GROUP_NAME¥tSM:SAMPLE_NAME¥tPL:PLATFORM' -t NUMBER_THREADS  
-x DNASCOPE_MODEL/bwa.model REFERENCE SAMPLE [SAMPLE2] || echo -n 'error' )  
| sentieon util sort -r REFERENCE -o SORTED_BAM -t NUMBER_THREADS --sam2bam -i -
```

sentieon bwa mem: マッピングを実行するコマンド

- R: BAMファイルのヘッダーを入力
- tID: リードに固有のID
- tSM: サンプルに固有のID
- tPL: プラットフォーム名
- t: スレッド数
- x: モデルファイルの場所** (Illumina以外のプラットフォームについては対応するモデルをgithubから入手)

Sentieon util sort: BAMファイルのソートを実行するコマンド

- r: リファレンス配列の場所／名前
- o: 出力ファイル名
- t: スレッド数

# DNAscopeを使用したJoint Calling②

## 重複リードの除去


```
sentieon driver -t NUMBER_THREADS -i SORTED_BAM  
  --algo LocusCollector --fun score_info SCORE.gz  
sentieon driver -t NUMBER_THREADS -i SORTED_BAM  
  --algo Dedup [--rmdup] --score_info SCORE.gz  
  --metrics DEDUP_METRIC_TXT DEDUPED_BAM
```

sentieon driver: パイプラインを実行するための主なコマンド

-t: スレッド数  
-i: 入力ファイル

--algo LocusCollector: 重複リード除去のために必要なリードの情報を集計  
--fun score\_info: スコア関数 (score\_info) の指定

--algo Dedup: 重複リードにフラグを付ける  
--rmdup: フラグが付いたリードの除去  
--score\_info: LocusCollectorの出力  
--metrics: 重複リード除去メトリクスの保存場所



# DNAscopeを使用したJoint Calling③

## gVCFファイルの作成（第1ステップ）

```
sentieon driver -t NUMBER_THREADS -r REFERENCE -i DEDUPED_BAM  
[--interval INTERVAL_FILE] --algo DNAscope [-d dbSNP] [--pcr_indel_model none]  
--model DNASCOPE_MODEL/dnascopemodel --emit_mode gvcf TMP_VARIANT_VCF
```

sentieon driver: パイプラインを実行するための主なコマンド

-t: スレッド数  
-r: リファレンス配列の場所／名前  
-i: 入力ファイル

--interval: BEDファイルの場所（オプション）

**--algo DNAscope:** DNAscopeでバリアントの検出  
**--pcr\_indel\_model:** ライブラリ作成の際にPCRを使用していない場合はnone  
**--model:** モデルファイルの場所  
**-d 既知バリアントデータ（オプション）**  
**--emit mode:** 出力するバリアントの指定 (variant, confident, all, gvcf)

# DNAscopeを使用したJoint Calling④

gVCFファイルの作成（第2ステップ）

```
sentieon driver -t NUMBER_THREADS -r REFERENCE --algo DNAModelApply --model  
DNASCOPE_MODEL/dnascoped.model -v TMP_VARIANT_GVCF VARIANT_GVCF
```

sentieon driver: パイプラインを実行するための主なコマンド

-t: スレッド数  
-r: リファレンス配列の場所／名前

--algo DNAModelApply: DNAscopeによるバリアントの検出の第2ステップを実施  
--model: モデルファイルの場所  
-v: 第1ステップの出力データ

# DNAscopeを使用したJoint Calling⑤

## Joint Calling

```
sentieon driver -r REFERENCE --algo GVCFtyper -v s1_VARIANT_GVCF -v s2_VARIANT_GVCF  
-v s3_VARIANT_GVCF VARIANT_VCF
```

sentieon driver: パイプラインを実行するための主なコマンド

-r: リファレンス配列の場所／名前

--algo GVCFtyper: バリアントコールのためのアルゴリズム

-v: 入力ファイル

Sentieonのドキュメントでは、さまざまな解析用のサンプルコードを提供

- ・生殖細胞変異検出 (DNAseq, DNAscope)
- ・体細胞変異検出 (TNseq, TNscope)
- ・RNAの変異検出
- ・ロングリードデータを使用した変異検出
- ・ハイブリッドアセンブルを利用した変異検出

など

お問い合わせ先：フィルジェン株式会社

TEL: 052-624-4388 (9:00～17:00)

FAX: 052-624-4389

E-mail: support@filgen.jp