

Paleofish Mitochondries

Objectif : Lancement de Eager sur référence majoritaire

CR 11 sept 2025

Voici les points abordés:

Présentation des résultats et des slides d'avancement envoyés par mail ce jour au groupe de travail: multimapping sur 44 références mito, répartition des jeux de données capture_janv22 par lot, pipelines Eager sur chaque lot, chemin d'accès aux résultats, exclusion des fichiers Sxx issus des fastq undetermined.

Lancement FastQScreen pour "coller" au pipeline Paleotrutta et pour se conforter sur les résultats du multimapping, sans a priori.

Il a été décidé:

Ne pas traiter les données shotgun car elles ne peuvent pas être exploitées par Joelle. Traiter uniquement les données capture. @Joelle : Confirmer le chemin d'accès et la liste des données à traiter : /work/project/crucial/PALEOFISH/DATA/capture_jan22

Ne pas traiter les jeux de données récupérés avec les barcodes depuis les fichiers Undetermined car les fichiers contiennent des reads non pairés. Ces fichiers *Sxx* sont donc archivés dans un nouveau répertoire Undetermined/ : smaman@genobioinfo2 /work/project/crucial/PALEOFISH/DATA/capture_jan22 \$ ls Undetermined/

L1_1_AUD20212-2_Sxx_R1_001_GACGATT+TCGCAGG.fastq L1_2_BC4_Sxx_R2_001_AACCTGC+CTCTGCA.fastq
L1_7_BC2_Sxx_R1_001_GTCCGGC+CTCGATG.fastq Undetermined_S0_R2_001.fastq.gz

L1_1_AUD20212-2_Sxx_R2_001_GACGATT+TCGCAGG.fastq L1_4_AUD11764-47_Sxx_R1_001_GCCTACG+GGATCAA.fastq
L1_7_BC2_Sxx_R2_001_GTCCGGC+CTCGATG.fastq

L1_2_BC4_Sxx_R1_001_AACCTGC+CTCTGCA.fastq L1_4_AUD11764-47_Sxx_R2_001_GCCTACG+GGATCAA.fastq Undetermined_S0_R1_001.fastq.gz

@Odile : Transmettre à Sarah la version BWA utilisée pour l'indexation de allRef.fasta

Reprendre l'ensemble des traitements multimapping avec les 39 ref mito du fichier /work/project/crucial/Ref_genomes/mito_genome/previous/allRef.fasta comme indiqué dans le mail de Joelle et en réunion ce jour.

Présentation des résultats sur multimapping sur 44 références mito. Joelle se demande donc s'il est intéressant d'affiner sur les références publiées intra-genre pour choisir la plus proche.

Joelle propose de lancer les étapes Eager uniquement sur le saumon et la truite. Pour les autres genres, nous nous laissons une semaine de réflexion.

Pipeline multimapping pour rechercher de les références majoritaires

Dans le répertoire : /work/project/crucial/PALEOFISH/02_eager/REF_MAJORITAIRE

0/ Indexation du multifasta de référence (00-BWA-index-fasta.sh) :/work/project/crucial/Ref_genomes/mito_genome/allRef_43_mito_genomes.fasta

1/ Nettoyage fastp des fichiers undetermined dos2unix (01-FASTP_fastp-0.23.2.sh)

2/ Alignement sur le multifasta pour trouver les références majoritaires (02-multiAlignPostFastp.sh)

3/ Convert SAM en BAM (03-convertSamtoBam.sh)

4/ Sort BAM (04-sortBam.sh)

5/ Index BAM trié (05-indexSortedbam.sh)

6/ Statistiques avec Samtools idxstats (06-samtools-idxstats.sh)

7/ Tri des statistiques (07-sort_stats.sh)

8/ Couverture des fichiers BED (08-coverage_bedtools.sh)

Removed -- 9/ Couverture médiane (09-median-coverage.sh)

10/ Liste des références majoritaires (10-sort_stats_MAJORITAIRE.sh)

Regroupement des échantillons par référence majoritaire avec 44 mito génomes

L0 2 EG5 S82	NC	001960.1
L0 8 SH2 S88	NC	001960.1
L10 11 SCO 1338 S63	NC	001960.1
L10 13 SCO 2764 S65	NC	001960.1
L1 1 AUD20212-2 Sxx GACGALL+PNC	NC	001960.1
L1 2 BC4 Sxx AACCTGC+CTCTGC	NC	001960.1
L1 4 AUD11/64-4/ Sxx GCCTACG	NC	001960.1
L2 10 MPH82 S78	NC	001960.1
L2 11 MPH83 S79	NC	001960.1
L2 12 MPH84 S80	NC	001960.1
L2 1 EG1 S71	NC	001960.1
L2 2 EG2 S72	NC	001960.1
L2 3 EG3 S73	NC	001960.1
L4 11 MD2 S21	NC	001960.1
L4 13 MB5 S23	NC	001960.1
L4 4 MB9 S14	NC	001960.1
L4 5 MD5 S15	NC	001960.1
L4 8 MB4 S18	NC	001960.1
L4 9 MD12 S19	NC	001960.1
L5 12 MD9 S37	NC	001960.1
L5 13 BC11 S38	NC	001960.1
L5 14 BC12 S39	NC	001960.1
L5 15 BC13 S40	NC	001960.1
L5 1 MD15 S26	NC	001960.1
L5 2 MD7 S27	NC	001960.1
L5 3 MD8 S28	NC	001960.1
L5 4 MD4 S29	NC	001960.1
L5 5 MD10 S30	NC	001960.1
L5 6 MB8 S31	NC	001960.1
L5 7 MD3 S32	NC	001960.1
L5 8 MD16 S33	NC	001960.1
L8 15 HTMK99-XXII-0-4287 S49	NC	001960.1
L9 1 26-52 S50	NC	001960.1
L9 2 2777-17 S51	NC	001960.1
L9 4 SM1 S52	NC	001960.1

Sample	Ref
L11 7 SCO 1354 S70	NC 006531.1

Sample	Ref
L0 1 EG4 S81	NC 010007.1
L0 3 EG6 S83	NC 010007.1
L0 6 EG13 S86	NC 010007.1
L0 7 OLG1 S87	NC 010007.1
L10 12 SCO 2213 S64	NC 010007.1
L2 6 TP1 S75	NC 010007.1
L2 7 TP2 S76	NC 010007.1
L3 10 MB13 S5	NC 010007.1
L3 11 MB18 S6	NC 010007.1
L3 13 MB11 S8	NC 010007.1
L3 14 MB10 S9	NC 010007.1
L3 6 MB3 S3	NC 010007.1
L3 9 MB17 S4	NC 010007.1
L4 2 MD13 S12	NC 010007.1
L4 7 MB1 S17	NC 010007.1
L5 10 MD11 S35	NC 010007.1
L5 11 MD14 S36	NC 010007.1
L5 9 MD6 S34	NC 010007.1
L6 11 SH2000-99-394-g S46	NC 010007.1
L6 13 SH2000-99-394-f S47	NC 010007.1
L6 3 SH1979-4-6843-e S41	NC 010007.1
L6 4 SH1979-4-6843-c S42	NC 010007.1
L6 6 SH2001-106 11-b S44	NC 010007.1
L9 15 SH2000-99-390-c S57	NC 010007.1
L9 6 SH1979-4-6843-b S53	NC 010007.1
L9 7 SH2000-99-394-c S54	NC 010007.1

Sample	Ref
L0 4 EG9 S84	NC 012928.1

Sample	Ref
L2 4 CD2 S74	NC 018341.1

Sample	Ref
L10 1 BC5 S58	NC 024032.1
L10 2 BC6 S59	NC 024032.1
L10 3 BC7 S60	NC 024032.1
L10 4 BC8 S61	NC 024032.1
L10 5 BC9 S62	NC 024032.1
L11 1 SCO 98 S66	NC 024032.1
L11 2 SCO 81 S67	NC 024032.1
L11 3 SCO 114 S68	NC 024032.1
L11 6 SCO 116 S69	NC 024032.1
L1 7 BC2 Sxx GTCGGGC+CTCGA	NC 024032.1
L2 8 BC1 S77	NC 024032.1
L3 12 MB6 S7	NC 024032.1
L3 15 MB12 S10	NC 024032.1
L3 1 MB15 S1	NC 024032.1
L3 5 SM3 S2	NC 024032.1
L4 10 BC14 S20	NC 024032.1
L4 12 MD1 S22	NC 024032.1
L4 14 SM2 S24	NC 024032.1
L4 15 BC10 S25	NC 024032.1
L4 1 MB14 S11	NC 024032.1
L4 3 MB16 S13	NC 024032.1
L4 6 MB2 S16	NC 024032.1
L6 5 SH1979-4-6843-d S43	NC 024032.1
L6 8 SH2000-99-394-e S45	NC 024032.1
L9 13 SH2000-99-390-b S55	NC 024032.1
L9 14 SH1979-4-6843-a S56	NC 024032.1

Sample	Ref
L0 5 EG10 S85	NC 025648.1
L7 14 22d S48	NC 025648.1



repartition_sample
by_ref_majoritair
e.ods

Regroupement des échantillons par référence majoritaire avec 39 mito génomes

```
snaman@genobioinfo1 /work/project/crucial/PALEOFISH/01_Multimapping $ cut -f 2 -d ':' RESULTATS_MAJORITAIRES | sort -u
NC_001960.1
NC_006531.1
NC_012928.1
NC_018341.1
NC_020762.1
NC_024032.1
```

Comme convenu en réunion le jeudi 11 septembre, le pipeline Eager est à lancer uniquement pour les échantillons classés pour ces 2 références :

NC_024032.1 : [Salmo trutta mitochondrion, complete genome](#)

NC_001960.1 : [Salmo salar mitochondrion, complete genome](#)

Regroupement des échantillons par référence majoritaire avec 39 mito génomes

```
smaman@genobioinfo1 /work/project/crucial/PALEOFISH/01_Multimapping $ cut -f 1,2 -d ':' RESULTATS_MAJORITAIRES | grep NC_001960.1
L0_2_EG5_S82:NC_001960.1
L0_8_SH2_S88:NC_001960.1
L10_11_SCO_1338_S63:NC_001960.1
L10_13_SCO_2764_S65:NC_001960.1
L1_1_AUD20212-2_Sxx_GACGATT+TCGCAGG:NC_001960.1
L1_2_BC4_Sxx_AACCTGC+CTCTGCA:NC_001960.1
L1_4_AUD11764-47_Sxx_GCCTACG+GGATCAA:NC_001960.1
L2_10_MPHB2_S78:NC_001960.1
L2_11_MPHB3_S79:NC_001960.1
L2_12_MPHB4_S80:NC_001960.1
L2_1_EG1_S71:NC_001960.1
L2_2_EG2_S72:NC_001960.1
L2_3_EG3_S73:NC_001960.1
L4_11_MD2_S21:NC_001960.1
L4_13_MB5_S23:NC_001960.1
L4_4_MB9_S14:NC_001960.1
L4_5_MD5_S15:NC_001960.1
L4_8_MB4_S18:NC_001960.1
L4_9_MD12_S19:NC_001960.1
L5_12_MD9_S37:NC_001960.1
L5_13_BC11_S38:NC_001960.1
L5_14_BC12_S39:NC_001960.1
L5_15_BC13_S40:NC_001960.1
L5_1_MD15_S26:NC_001960.1
L5_2_MD7_S27:NC_001960.1
L5_3_MD8_S28:NC_001960.1
L5_4_MD4_S29:NC_001960.1
L5_5_MD10_S30:NC_001960.1
L5_6_MB8_S31:NC_001960.1
L5_7_MD3_S32:NC_001960.1
L5_8_MD16_S33:NC_001960.1
L8_15_HTMK99-XXII-0-4287_S49:NC_001960.1
L9_1_26-52_S50:NC_001960.1
L9_2_2777-17_S51:NC_001960.1
L9_4_SM1_S52:NC_001960.1
others_underterminated_R1:NC_001960.1
Undetermined_S0:NC_001960.1
```


Regroupement des échantillons par référence majoritaire avec 39 mito génomes

```
smaman@genobioinfo1 /work/project/crucial/PALEOFISH/01_Multimapping $ cut -f 1,2 -d ':' RESULTATS_MAJORITAIRES | grep NC_024032.1
L0_1_EG4_S81:NC_024032.1
L0_3_EG6_S83:NC_024032.1
L0_6_EG13_S86:NC_024032.1
L0_7_OLG1_S87:NC_024032.1
L10_12_SCO_2213_S64:NC_024032.1
L10_1_BC5_S58:NC_024032.1
L10_2_BC6_S59:NC_024032.1
L10_3_BC7_S60:NC_024032.1
L10_4_BC8_S61:NC_024032.1
L10_5_BC9_S62:NC_024032.1
L11_1_SCO_98_S66:NC_024032.1
L11_2_SCO_81_S67:NC_024032.1
L11_3_SCO_114_S68:NC_024032.1
L11_6_SCO_116_S69:NC_024032.1
L1_7_BC2_Sxx_GTCCGGC+CTCGATG:NC_024032.1
L2_6_TP1_S75:NC_024032.1
L2_7_TP2_S76:NC_024032.1
L2_8_BC1_S77:NC_024032.1
L3_10_MB13_S5:NC_024032.1
L3_11_MB18_S6:NC_024032.1
L3_12_MB6_S7:NC_024032.1
L3_13_MB11_S8:NC_024032.1
L3_14_MB10_S9:NC_024032.1
L3_15_MB12_S10:NC_024032.1
L3_1_MB15_S1:NC_024032.1
L3_5_SM3_S2:NC_024032.1
L3_6_MB3_S3:NC_024032.1
L3_9_MB17_S4:NC_024032.1
L4_10_BC14_S20:NC_024032.1
L4_12_MD1_S22:NC_024032.1
L4_14_SM2_S24:NC_024032.1
L4_15_BC10_S25:NC_024032.1
L4_1_MB14_S11:NC_024032.1
L4_2_MD13_S12:NC_024032.1
L4_3_MB16_S13:NC_024032.1
L4_6_MB2_S16:NC_024032.1
L4_7_MB1_S17:NC_024032.1
```

```
L5_10_MD11_S35:NC_024032.1
L5_11_MD14_S36:NC_024032.1
L5_9_MD6_S34:NC_024032.1
L6_11_SH2000-99-394-g_S46:NC_024032.1
L6_13_SH2000-99-394-f_S47:NC_024032.1
L6_3_SH1979-4-6843-e_S41:NC_024032.1
L6_4_SH1979-4-6843-c_S42:NC_024032.1
L6_5_SH1979-4-6843-d_S43:NC_024032.1
L6_6_SH2001-106_11-b_S44:NC_024032.1
L6_8_SH2000-99-394-e_S45:NC_024032.1
L9_13_SH2000-99-390-b_S55:NC_024032.1
L9_14_SH1979-4-6843-a_S56:NC_024032.1
L9_15_SH2000-99-390-c_S57:NC_024032.1
L9_6_SH1979-4-6843-b_S53:NC_024032.1
L9_7_SH2000-99-394-c_S54:NC_024032.1
```

Pipeline et paramétrages mito

Phase 1 : Premier lancement d'Eager

tsv_modif.sh : Génération du fichier d'entrée input.csv listant les FastQ en entrée d'Eager.
01_script_eager_part1_NC_001960.1.sh

Phase 2 : Filtre des BAM pour ne conserver que les séquences mito

02_rehead_bam_files_v2_NC_001960.1.sh : Enlever les séquences génomiques du BAM pour ne conserver que les séquences mito. Sinon fichier FASTQ trop gros qui fait planter le script 3.

02bis-bam_tsv.sh : Créer le fichier tabulé listant les BAM, en entrée de la phase 2 d'Eager.

Phase 3 : Second lancement d'Eager uniquement sur les mitochondries

03_script_eager_only_genotyping_v2.sh : Skip des étapes précédentes avec les étapes GATK et VCF.

Résultats du pipeline pour S. salar et S. trutta

```
/work/project/crucial/PALEOFISH/02_eager_39_mito_genomes/crucial_nextflow_VersionPaleofish.config

/work/project/crucial/PALEOFISH/02_eager_39_mito_genomes/NC_001960.1:
01_script_eager_part1_NC_001960.1.sh 03_eager_only_genotyping documentation input_NC_001960.1.tsv pipeline_info reference_genome slurm-24635376.out
02bis-bam_tsv.sh adapterremoval endorspy mapdamage pipeline_trace.txt reheader_bam slurm-24635526.out
02_rehead_bam_files_v2_NC_001960.1.sh crucial_nextflow_VersionPaleofish.config FastP mapping preseq samtools work
02ter_tsv_modif.sh deduplication fastqc multiqc qualimap slurm-24562555.out

/work/project/crucial/PALEOFISH/02_eager_39_mito_genomes/NC_024032.1:
01_script_eager_part1_NC_024032.1.sh 03_eager_only_genotyping FastP L4_6_MB2_slurm-24562820.out pipeline_trace.txt work
02bis-bam_tsv.sh adapterremoval fastqc OLD_with_Sxx_input_NC_024032.1.tsv reference_genome
02_rehead_bam_files_v2_NC_024032.1.sh documentation input_NC_024032.1.tsv pipeline_info slurm-24635219.out
smaman@qenobioinfo1 /work/project/crucial/PALEOFISH/02_eager_39_mito_genomes/NC_024032.1 $
```