PEPI Ingénierie Bio Informatique et Statistique pour les données haut-débit (IBIS) Annotation, Intelligence Artificielle et Text-mining. - 28 novembre 2022

Méthode d'apprentissage profond pour l'analyse génomique des cancers canins comme modèles des cancers

Christophe HITTE

University of Rennes, CNRS, France









Genome Annotation

• ~2% of DNA is made up of protein-coding genes + 98% is noncoding

noncoding DNA : Regulatory elements

- promoters
- enhancers
- silencers
- insulators

noncoding RNA :

- short lengths of RNAs (microARN, tRNA, rRNA)
- long noncoding RNAs (IncRNAs)

>60% of the genome is transcribed into RNAs

• Incomplete genome annotation impact genomic analyses :

- Gene structure identification
- Regulatory sequences identification
- Differential Gene Expression
- Variants annotation
- etc...
- Genome Wide Association Analysis

80% of the variants associated with diseases localized <u>outside</u> of protein-coding genes (*Manolio et al., Hindorff et al*)

The computation phase of genome annotation

Ab initio Gene Prediction

- Mathematical models rather than external evidence to identify the genes [GenomeScan, GeneWise, GeneID, Augustus, Splign, etc]

Evidence Alignment Stage

- ESTs, RNA-seq, and protein sequences are aligned to the assembled genome [STAR, Histar, Kallisto, etc.]
- Assemble transcripts [cufflinks, stringtie2, etc.]

Quality Control and Representation of annotated data

GTF/GFF format :

- uses controlled vocabularies
- guarantees interoperability between different analysis tools

DEEP LEARNING



Complex patterns detection in large datasets

Outperform traditional approaches of machine learning

 Several models have been developed to predict gene expression or chromatin profiles from the DNA sequence : Xpresso, DeepSEA, Basset, Basenji, Enformer, etc.

DEEP LEARNING



Complex patterns detection in large datasets

Outperform traditional approaches of machine learning

Many applications in genomics fields

Unsupervised methods DNA sequences taxonomic classification Supervised methods Genomic sequences annotation, gene expression prediction

 Several models have been developed to predict gene expression or chromatin profiles from the DNA sequence : Xpresso, DeepSEA, Basset, Basenji, Enformer, etc.

CROSS- / WITHIN-SPECIES

Generalizable predictive models

Cross-species predictions

- * Take advantage of available data in one species to transfer knowledge to other species
- * Enhancers detection in mouse genomic sequences with human prediction model

	0	
PLOS	COMPUTATIONAL BIOLOGY	

2018

RESEARCH ARTICLE

Prediction of gene regulatory enhancers across species reveals evolutionarily conserved sequence properties

Ling Chen₀¹⁰, Alexandra E. Fish²⁰, John A. Capra₀^{1,2,3}*

Species-specific prediction models are powerful tools

Within-species predictions

* High performance

Method=

Domain-adaptive neural networks improve crossspecies prediction of transcription factor binding

Kelly Cochran,^{1,2} Divyanshi Srivastava,^{1,3} Avanti Shrikumar,² Akshay Balsubramani,⁴ Ross C. Hardison,^{1,3} Anshul Kundaje,^{2,4} and Shaun Mahony^{1,3} 2022

* Predictions from whole DNA sequence (not only conserved regions)

· PhD Camille KERGAL : OBJECTIVES



- Creation of a deep learning model to predict canine gene expression
 - Data collection
 - Optimization strategy

- Assessment of the dog prediction model
 - Within-species and cross-species predictions

Prediction of the impact of regulatory mutations on gene expression

Method

Sequential regulatory activity prediction across chromosomes with convolutional neural networks

David R. Kelley,¹ Yakir A. Reshef,² Maxwell Bileschi,³ David Belanger,³ Cory Y. McLean,³ and Jasper Snoek³ 2018

- Tissue specific predictions of human gene expression and impact of mutations from DNA sequence
- Model CAGE signals as a function of DNA
- High correlations between predicted and expected expression
- Well documented tool: codes and prediction model publicly available on GitHub



Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0100001100001001001000010... encodage One-hot

2eme ÉTAPE

Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0 0 1 0 0 0 0 1 1 0 0 0 0 1 0 0 1 0 0 0 0 1 0 0 encodage One-hot

2eme ÉTAPE

-2.8 -0.1 0.6 0 0 0 -2.8 -2.9 0.5 0.6 0 0 0 -2.8 -0.1 0.6 -2.8 -0.1 convolution

Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0 0 1 0 0 0 0 1 1 0 0 0 0 1 0 0 1 0 0 0 0 1 0 0 encodage One-hot

2eme ÉTAPE

-2.8 -0.1 0.6 0 0 0 -2.8 -2.9 0.5 0.6 0 0 0 -2.8 -0.1 0.6 -2.8 -0.1 convolution

0 0 0.6 0 0 0 0 0 0.5 0.6 0 0 0 0 0 0.6 0 0 activation

Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0 0 1 0 0 0 0 1 1 0 0 0 0 1 0 0 1 0 0 0 0 1 0 0 encodage One-hot

2eme ÉTAPE

-2.8 -0.1 0.6 0 0 0 -2.8 -2.9 0.5 0.6 0 0 0 -2.8 -0.1 0.6 -2.8 -0.1

0	0	0.6	0	0	0	0	0	0.5	0.6	0	0	0	0	0	0.6	0	0
		•					•		•		•						
	•	• •	,		•			•	•		•		•		•		•
		* *			•								•				*
		* *				•											*
		* *															*
		* *			•				•		•						•
		* *			•				•								*
		* *			•	•	•		*		•						•
	*	* *			*	•	*	•	•	•	*		*				•
	•				•	•	•	•		•			•				•
-		547 			•	•	•	1			H		•		4	-	•
C)	0.6)	()	()	0.	.6	(0	()	0	.6	()

convolution

activation

agrégation

Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0 0 1 0 0 0 0 1 1 0 0 0 0 1 0 0 1 0 0 0 0 1 0 0 encodage One-hot

				2er	me ÉTAPE
-2.8 -0.1 0.6	0 0 0 -2.8 -2.9	9 0.5 0.6 0 0	0 -2.8 -0.1 0.6	-2.8 -0.1	convolution
0 0 0.6		0.5 0.6 0	0000.6	00	activation
0 0.6	0 0	0.6 0	0 0.6	0	agrégation

Réseau de neurones convolutif (CNN)

1ere ÉTAPE

CTAGCGTGGCTATCGT

séquence ADN

0 0 1 0 0 0 0 1 1 0 0 0 0 1 0 0 1 0 0 0 0 1 0 0 encodage One-hot

Development of canine gene expression prediction model

Adaptation of Basenji

Collaboration with DoGA consortium

- * Most comprehensive set of canine CAGE profiles
- * 116 canine CAGE profiles representing 37 core tissues

project consortium

University of Helsinki, Karolinska Institutet

Basenji-Like IMpacting variant Prediction

https://github.com/ckergal/BLIMP

- * Recommendations about how to process CAGE data and how to use prediction model
- * Promoting the canine prediction model

Min 0,18	Max 0,76	Median 0,64
Min 0,30	Max 0,74	Median 0,63

Min 0,18	Max 0,76	Median 0,64
Min 0,30	Max 0,74	Median 0,63

- Hyperparameters optimisation
- * Focus on Learning Rate and L2 Scale
- * Selection of the model leading to the best median Pearson correlation

Min 0,18	Max 0,76	Median 0,64
Min 0,30	Max 0,74	Median 0,63
Min 0,34	Max 0,75	Median 0,65

- Hyperparameters optimisation
- * Focus on Learning Rate and L2 Scale
- * Selection of the model leading to the best median Pearson correlation

0.60 0.63 0.66

< 0.58

Median Pearson according to HP values

· (PhD Camille KERGAL) OBJECTIVES

- Creation of a deep learning model to predict canine gene expression
 - Data collection
 - Optimization strategy In order to obtain the most powerful prediction model

- Assessment of the dog prediction model
 - Within-species and cross-species predictions

Orthologous genes between human and dog
 Focus on genes implicated in cancers

Wong et al. 2021 <u>nanoString</u>

Matching tissues between both species

- 18 common samples
 - * 638 composing the human prediction model
 - * 116 composing the dog prediction model

METHOD · CROSS-SPECIES / WITHIN-SPECIES

Within-species (dog specific) compared to cross-species predictions

METHOD · CROSS-SPECIES / WITHIN-SPECIES

Within-species (dog specific) compared to cross-species predictions

Canine sequence prediction assessment for each matching tissues

Canine genomic features influencing cross-species predictions

 Cross-species approach leads to better results when dog sequences features approximate human genomics features

Canine genomic features influencing cross-species predictions

 Cross-species approach leads to better results when dog sequences features approximate human genomics features

Canine genomic features influencing cross-species predictions

 Cross-species approach leads to better results when dog sequences features approximate human genomics features

OBJECTIVES · THIRD PART

- Creation of a deep learning model to predict canine gene expression
 - Data collection
 - Optimization strategy In order to obtain the most powerful prediction model

- Assessment of the dog prediction model
 - Within-species and cross-species predictions Performance comparison

- Prediction of the impact of regulatory mutations on gene expression
 - In silico saturated mutagenesis in promoters of cancer genes
 - Analysis of variants predicted as impacting

Predictions of non-coding mutations impact in TERT promoters relevant with the human model

- Application de mutagenèse saturée in silico
 - Gènes orthologues
 - * Promoteurs : 1024 nucléotides en amont du TSS

- Modèles de prédiction de l'expression
 - * Utilisation des deux modèles : modèle humain / modèle canin
 - * Prédictions dans 19 tissus

L'outil prédit un score d'impact pour chaque mutation possible

1024 positions génomiques X 1317 gènes X 4 mutations X 19 tissus

+ 100 millions de prédictions

Nombreuses mutations sans impact sur le niveau d'expression

(Allèle muté identique à l'allèle de référence)

Caractérisation des variants selon la prédiction d'impact

sans impact	impact faible à modéré	impact fort
écart-type entre 0 et 4	entre 4 et 8	> 8

L'outil prédit un score d'impact pour chaque mutation possible

```
1024 positions génomiques X 1317 gènes X 4 mutations X 19 tissus
```

+ 100 millions de prédictions

Nombreuses mutations sans impact sur le niveau d'expression

(Allèle muté identique à l'allèle de référence)

Caractérisation des variants selon la prédiction d'impact

sans impact	impact faible à modéré	impact fort
écart-type entre 0 et 4	entre 4 et 8	> 8
 Prédictions de n 	nutations à fort impact	
103 000 (7,6%) ch	ez le chien / 98 000 (7,2%)	chez l'humain
	.50	

- Étude comparative entre l'humain et le chien
 - * 7,6% des mutations possibles sont prédites avec un fort impact chez le chien / 7,2% chez l'humain

Distance au TSS des variants fortement impactants

- Étude comparative entre l'humain et le chien
 - * 7,6% des mutations possibles sont prédites avec un fort impact chez le chien / 7,2% chez l'humain

Nombre moyen de mutations détectées par gènes

- Étude comparative entre l'humain et le chien
 - * 7,6% des mutations possibles sont prédites avec un fort impact chez le chien / 7,2% chez l'humain

Données Dog10K : chien/loup/chien-village :

n=2000 WGS -> 33 millions de variants

15 500 variants identifiés parmi les promoteurs du panel de gènes (1317)

* 3 catégories :

sans impact	impact faible à modéré	impact fort	
écart-type entre 0 et 4	entre 4 et 8	> 8	

- Données Dog10K : chien/loup/chien-village : n=2000
- 15 500 variants identifiés parmi les promoteurs du panel de gènes (1317)

* Identification de **186** variants représentés dans la base de données Dog10K et prédits avec un **impact fort** sur l'expression des gènes cancers

Données Dog10K : 15 500 variants identifiés dans la population des canidés

Données Dog10K : 15 500 variants identifiés dans la population des canidés

* Chiens : nombre de variants à fort impact statistiquement plus élevé que chez les loups ou les chiens de village

Données Dog10K : 15 500 variants identifiés dans la population des canidés

31 à fort impact

- Hiérarchisation des variants du Dog10K
 Catégorisation selon l'impact
- Maintien de variants délétères

Conséquence probable de sélection artificielle

* Chiens : nombre de variants à fort impact statistiquement plus élevé que chez les loups ou les chiens de village

canFam3 / canFam4

- Creation de modèles optimisés de l'expression des gènes canins
 - * Performances **équivalentes** avec le modèle de l'expression des gènes humains
 - * Intérêt de l'approche intra-espèce

canFam3 / canFam4

- Creation de modèles optimisés de l'expression des gènes canins
 - * Performances **équivalentes** avec le modèle de l'expression des gènes humains
 - * Intérêt de l'approche intra-espèce

- Analyse des régions régulatrices des gènes de cancer
 - * Évaluation de la mutagenèse saturée in silico de l'outil Basenji
 - * Utilisation avec le modèle humain et le modèle canin

canFam3 / canFam4

- Creation de modèles optimisés de l'expression des gènes canins
 - * Performances **équivalentes** avec le modèle de l'expression des gènes humains
 - * Intérêt de l'approche intra-espèce

- Analyse des régions régulatrices des gènes de cancer
 - * Évaluation de la mutagenèse saturée in silico de l'outil Basenji
 - * Utilisation avec le modèle humain et le modèle canin

- Identification de mutations impactantes
 - * Analyse comparative entre l'humain et le chien
 - * Croisement avec des variants présents dans la population canine

- Creation of optimized prediction models of canine gene expression
 - * Equivalent performance with the human gene expression model
 - * Relevance of the within species approach

canFam3 and

UU_Cfam_GSD

versions

CONCLUSION

- Creation of optimized prediction models of canine gene expression
 - * Equivalent performance with the human gene expression model
 - * Relevance of the within species approach
 - Analysis of cancer genes regulatory regions
 - * Assessment of the *in silico* saturated mutagenesis of the Basenji tool
 - * Identification of non-coding mutations potentially involved in cancers
 - * Promoting the canine prediction model with **BLIMP**

Basenji-Like IMpacting variant Predictor

https://github.com/ckergal/BLIMP

versions

- Camille Kergal
- Thomas Derrien
- Marie Dominique Galibert
- Dog Genetics Team

- Hannes Lohi
- Matthias Hortenhuber

Hosting structures and funding

