Protein Threading Algorithms Used in Protein Structure Prediction

Yuting Xiao

Division of Science and Mathematics University of Minnesota, Morris

April 15, 2017

Outline

Background

Introduction

Sequence Profile-Profile Alignment(PPAs)

Profile-Hidden Markov Models(HMMs)

Summary

Background

Amino Acids

- Amino acids, also called residues.
- 20 different amino acids
- Unique single letter
- > Primary Structure, linear combination of amino acids

▲ロト ▲帰ト ▲ヨト ▲ヨト 三回日 のの⊙

- Secondary Structure, natural folds
- **Tertiary Structure**, 3-D structure

Background

Protein Structure



Figure: Protein Structure

Why predicting protein structure?

- Basic Strategy
- Template-Based Modeling

Why predicting protein structure?

- One important topic
- Functionality is closely related to structures

(日)

Discovering novel drugs for diseases

Basic Strategy

- Unknown protein's primary structure (target)
- Currently known protein structures (templates).
- Constructing target's structure based on templates' structures

Basic Strategy

- Protein Data Bank (PDB):
 - Templates
 - Coordinate Files
 - ► Atoms in each protein, and their 3D location in space

▲ロト ▲帰ト ▲ヨト ▲ヨト 三回日 のの⊙

- Modeling Method
 - Template-Based Modeling
 - Free Modeling

Template-Based Modeling



Figure: Protein Threading

◆□> <□> <=> <=> <=> <=> <=> <=> <=>

Template-Based Modeling

- Aligned Regions
- Unaligned Regions

- Sequence
- Pairwise Sequence Alignment
- Multiple Sequence Alignment and Profile

▲ロト ▲帰ト ▲ヨト ▲ヨト 三回日 のの⊙

- PPA Program
- Improvement

Sequence

L --- Leucine E --- Glutamic Acid D --- Aspartic Acid V --- Valine I --- Isoleucine K --- Lysine R --- Arginine

▲ロト ▲冊 ▶ ▲ヨト ▲ヨト 三回 のへの

Sequence 1 :L E V KSequence 2 :L D I RSequence 3 :L E I KSequence 4 :L D V E

Pairwise Sequence Alignment

There are many ways to align two protein sequences, and for each amino acid pair, we can find either a match (blue), a mismatch (red) or an insertion or deletion ("-" represents a gap)

 Index :
 0
 1
 2
 3
 4

 Sequence 1:
 L
 E
 V
 K

 Sequence 2:
 L
 D
 I
 K

Figure: Pairwise Sequence Alignment

Pairwise Sequence Alignment

If we adopt a scoring method for each possible alignment, the best alignment is therefore the one with the highest score.

> Match +2 Mismatch 0 Gap -1 Index : 0 1 2 3 4 Sequence 1: L E V - K Sequence 2: L D - I K +2 +0 -1 -1 +2 =2

Figure: Pairwise Sequence Alignment

▲ロト ▲帰ト ▲ヨト ▲ヨト 三回日 のの⊙

Multiple Sequence Alignment

► A profile is a 20 by *L* table of frequencies for a multiple sequence alignment with length *L*. Each entry *p_{i,j}* represents the probability of amino acid type *i* occur in the *j* th column.

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

 Profile is a better representation for multiple sequence alignment.

Profile

L --- Leucine E --- Glutamic Acid D --- Aspartic Acid V --- Valine I --- Isoleucine K --- Lysine R --- Arginine

▲ロト ▲冊 ▶ ▲ヨト ▲ヨト 三回 のへの

Sequence 1 :L E V KSequence 2 :L D I RSequence 3 :L E I KSequence 4 :L D V E

Figure: Protein Sequence Examples

Profile

	Index 0	Index 1	Index 2	Index 3	
D	-	0.5	-	-	
Е	-	0.5	-	0.25	
L	1	-	-	-	
Ι	-	-	0.5	-	
V	-	-	0.5	-	
R	-	-	-	0.25	
Κ	-	-	-	0.5	

PPA program

I-TASSER

 PPA program reduces multiple sequence alignments to pairwise alignment between profiles

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

PPA program

 Use target sequence as input, and search through PDB using PSI-BLAST

>NP_002583.1 proliferating cell nuclear antigen [Homo sapiens] MFEARLVQGSILKKVLEALKDLINEACWDISSSGVNLQSMDSSHVSLVQL TLRSEGFDTYRCDRNLAMGVNLTSMSKILKCAGNEDIITLRAEDNADTLA LVFEAPNQEKVSDYEMKLMDLDVEQLGIPEQEYSCVVKMPSGEFARICRD LSHIGDAVVISCAKDGVKFSASGELGNGNIKLSQTSNVDKEEEAVTIEMN EPVQLTFALRYLNFFTKATPLSSTVTLSMSADVPLVVEYKIADMGHLKYYLA PKIEDEEGS

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

PPA program

Descriptions	Seq	Seq		
	Start	100 110 120 130 140 150 160 170 180 190 200 210 220 230 240 250 280 270 280 290 300 310 320 330 3	-	
NP_002583	1		261	Homo sapiens
5IY4_A	+ 1		261	
AAX43156.1	+ 1		261	synthetic construct
4D2G_A	1 4		264	Homo sapiens
AAX36355.1	+ 1		261	synthetic construct
XP_003933273.1	+ 1		261	Saimiri bolwensis bolwensis
EHH19900.1	+ 1		261	Macaca mulatta
NP_001278854.1	+ 1		261	Sus scrofa
EHH65526.1	1		261	Macaca fascicularis
1AXC_C	+ 2		-261	Homo sapiens
xP_019589397.1	+ 1		261	Rhinolophus sinicus
XP_017517834.1	+ 1		261	Manis javanica
XP_010971028.1	+ 1		261	Camelus bactrianus
XP_004383101.1	+ 1		261	Trichechus manatus latirostris
XP_004276492.1	+ 1		261	Orcinus orca
XP 006164047.1	+ 1		261	Tupaia chinensis
XP_003411475.1	1		261	Loxodonta africana
NP_001297174.1	+ 1		261	Heterocephalus glaber
NP_001029666.1	+ 1		261	Bos taurus
CAG38740.1	+ 1		261	Homo sapiens
XP 006894289.1	+ 1		261	Elephantulus edwardii
XP_007539624.1	Image: A marked block in the second secon		261	Erinaceus europaeus
XP_020033921.1	+ 1		261	Castor canadensis
CP_001494771.1	+ 1		261	Equus caballus
CAG46598.1	+ 1		261	Homo sapiens
XP 004661551.1	Image: 1		261	Jaculus jaculus
CP_004611042.1			261	Sorex araneus
(P_003476647.1	- • • i		261	Cavia porcellus
NP 071776.1	- • • •		261	Rattus nonvegicus
XP 012967724.1	- • • • •		261	Mesocricetus auratus
NP 001233697.1			261	Cricetulus griseus
XP 005974376.1			263	Parthologs hodgsoni
YD 011920710 1			250	Mandellar Incontinuer

PPA program

- Construct target profiles
- Align target profiles against all pre-calculated profiles in database, where each profile represents a specific set of protein families

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

PPA program Scoring function

Use dynamic programming to find the overall best alignment



▲ロト ▲冊 ▶ ▲ヨト ▲ヨト 三回 のへの

New Improvement in I-TASSER Suite

• Added structural environment fitness score, $E(j, AA_q(i))$

- torsion angle
- solvent accessibility
- secondary structure

$$S_{\text{Env-PPA}}(i,j) = S(i,j) + c_2 E(j, AA_q(i))$$

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

Structures

- Coin Toss Example
- Profile-HMM
- Pairwise Profile-HMM Alignment

- Scoring function
- Improvements

Structures

- Two layers structure:
 - Visible layer
 - Invisible layer
- Markov chain

Coin Toss Example

 Given two coins that has different probability of heads and tails:

	Coin A	Coin B
Head (H)	0.5	0.3
Tail (T)	0.5	0.7

- Suppose we are given an observation sequence of HHTHTH
- Without knowing which coin was used for each toss
- What would the best explanation for an observations of such sequence?

(日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 (日)

 (日)
 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)

 (日)
 </p

Coin Toss Example

Transition probabilities are given as below:

	Coin A	Coin B
Coin A	0.9	0.2
Coin B	0.1	0.8



Figure: Hidden Markov Model for Coin Toss Example

Coin Toss Example



- If the coin sequence is AABAAB
- The probability for observations HHTHTH is:

P = 0.5 * 0.9 * 0.5 * 0.1 * 0.7 * 0.2 * 0.5 * 0.9 * 0.5 * 0.1 * 0.3= 2.12625 * 10⁻⁵

▲ロト ▲帰ト ▲ヨト ▲ヨト 三回日 のの⊙

Profile-HMM

HHpred



Figure: Example of a Profile-Hidden Markov Model

Profile

	Index 0	Index 1	Index 2	Index 3
D	-	0.4	-	-
Е	-	0.4	-	0.2
L	0.8	-	-	-
I	-	-	0.4	-
V	-	-	0.4	-
R	-	-	-	0.2
K	-	-	-	0.4
Insert	0.1	0.1	0.1	0.1
Delete	0.1	0.1	0.1	0.1

Profile-HMM



・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

Pairwise Profile-HMM Alignment

• Example of a pairwise profile-HMM alignment:



Profile-HMMs Scoring Function

- Five possible pair states can co-emit amino acids or gaps: MM, MI, IM, DG and GD
- Log-sum-of-odds Score:

$$S_{LSO} = \log \sum_{x_1,...,x_L} \frac{P(x_1,...,x_L | \text{co-emission on path})}{P(x_1,...,x_L | \text{Null})}$$

Profile-HMMs Scoring Function

$$S_{LSO} = \sum_{k:X_k Y_k = MM} S_{aa}(q_{i(k)}, p_{j(k)}) + \log \mathcal{P}_{tr}$$

Column Score:

$$S_{aa}(q_i,p_j) = \log \sum_{a=1}^{20} rac{q_i(a)p_j(a)}{f(a)}$$

Also use dynamic programming, with a dynamic matrix for each co-emit state pair, to determine the best alignment

New Improvement

 Reaserchers Xin Deng and Jianlin Cheng from University of Missouri-Columbiacan

- Additional structural information
 - protein solvent accessibility
 - torsion angles
- Improved alignment accuracy

Summary

Critical Assessment of protein Structure Prediction (CASP)

- ▶ The I-TASSER server (zhang-server) top 3 places
- The HHpred server top 10 places

Summary

- We looked at two different and popular approaches used in protein threading process
- Many different improvements have been proposed for both methods
- However, there is no single method outperforms all others on every target yet, which leaves room for improvement

References I

- S. F. Altschul, J. C. Wootton, E. Zaslavsky, and Y.-K. Yu. The construction and use of log-odds substitution scores for multiple sequence alignment. Computational Biology, 2010.
- X. Deng and J. Cheng.

Enhancing hmm-based protein profile-profile alignment with structural features and evolutionary coupling information. *BMC Bioinformatics*, 2014.

 A. Roy, A. Kucukural, and Y. Zhang.
 I-tasser: a unified platform for automated protein structure and function prediction.

Nature protocols, 5(4):725738, 2010.

J. Söding.

Protein homology detection by HMMHMM comparison. *Bioinformatics*,21(7):951960, 2005.

References II

J. Yang, R. Yan, A. Roy, D. Xu, J. Poisson, and Y. Zhang. The I-TASSER suite: protein structure and function prediction.

Nature methods, 12(1):78, 2015.

J. Yang and Y. Zhang.

Protein structure and function prediction using I-TASSER. *Current protocols in bioinformatics*, pages 58, 2015.

B.-J. Yoon.

Hidden markov models and their applications in biological sequence analysis.

Current genomics, 10(6): 402415, 2009.

📔 Y. Zhang.

Progress and challenges in protein structure prediction.

Current opinion in structural biology,18(3):342348, 2008.

Questions?

◆□ ▶ < @ ▶ < E ▶ < E ▶ E ■ 9 Q @</p>

Thank You!

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・