

단백질에서의 RNA 결합 부위 예측

김현우⁰, 한경숙
인하대학교 전자계산공학과
whytok⁰@hanmail.net, khan@inha.ac.kr

Prediction of the RNA Binding Sites of Proteins

Hyunwoo Kim⁰, Kyungsook Han
School of Computer Science and Engineering, Inha University

요약

PDB로부터 얻은 51개의 단백질-RNA 복합체를 대상으로 기존 연구에서 얻은 단백질과 RNA의 결합 성향성 값과 본 논문에서 새로 구한 단백질의 표면 노출정도에 따른 결합 성향성 값을 이용하여 단백질의 결합 기대치를 구한다. 또한 구한 결합 기대치를 활용하여 새로운 단백질-RNA 복합체를 대상으로 단백질의 결합 부위 예측을 시도하였다. 결합 기대치는 0.240 이상인 경우 결합할 가능성이 높은 것으로 판별하였고, 그 결과 단백질의 결합 후보지를 전체 단백질의 25% 정도로 줄일 수 있었다.

1. 서 론

단백질-단백질 interaction을 밝히는 것은 단백질의 기능을 알아내기 위한 필수적인 과정이기 때문에, 해당 연구는 그 중요성이 인지되어 각지에서 활발히 진행되고 있다. 단백질-단백질 interaction이 bioinformatics의 주요한 이슈이긴 하지만 단백질은 단백질 뿐 아니라 RNA나 DNA와도 interaction 하며 이 또한 중요한 문제이다. 이를 테면 유전자 전사 과정이나 RNA의 효소 작용이 그와 관련된 예이다. 특히 단백질-RNA interaction은 RNA 질병 치료를 위한 약이나 RNA를 이용한 신약 설계에도 응용 될 수 있는 상업적 잠재력 마저 가지고 있어 점차 그 관심은 증가하고 있는 추세이다.

본 논문은 RNA와 interaction 하는 것으로 알려진 단백질을 가지고 해당 단백질의 부위 중 RNA와 interaction 할 가능성이 높은 부위를 찾아내는 기법을 기술한다. 포켓을 이용하여 구조적 접근을 하는 방법으로 interaction 후보지를 구하는 기준 연구 [1]가 있지만, 본 연구에서는 단백질의 각 부위별로 각 아미노산의 종류와 그 접근성을 가지고 interaction 기대치를 계산하는 방법을 이용한다. 본 논문에서는 몇 가지 bioinformatics 분야의 어플리케이션을 이용했으며, 그 결과를 조합하고 분석하기 위해 Python [2]를 이용했다.

2. 데이터 선정 및 구현 방법

2.1 분석데이터 선정

분석 데이터로 PDB [3]에 있는 단백질-RNA complex를 사용했다. 기본적으로 X-ray crystallography 기법에 의해 밝혀진 복합체 중 해상도가 3.0 Å 이하인 것을 선정하였으

며 PSI-BLAST [4]를 이용하여 상동 단백질을 제외 시켜 같은 복합체의 중복된 분석을 피했다. PSI-BLAST 옵션은 *E* 값을 0.001, *identities* 값은 80% 이상으로 적용하였으며, 그 결과 상동 복합체로 판단되는 것은 제외하고 51개의 단백질-RNA complex를 분석 데이터로 선정했다. 표1은 본 연구의 분석에 사용된 51개 복합체의 PDB ID를 생물학적 기능별로 분류하여 나열한 것이다.

표 1 분석에 사용된 PDB Data

tRNA	15	1B23, 1H4Q, 1C0A, 1H4S, 1EFW 1IL2, 1F7U, 1QF6, 1FFY, 1QTQ 1G59, 1SER, 1GAX, 2FMT, 1K8W
mRNA	1	1B7F
ribosome	6	1DK1, 1DFU, 1FEU, 1HC8, 1I6U, 1MMS
ribozyme	4	1CX0, 1B2M, 1JBR, 1JBS 1E7X, 1HDW, 1HE0, 1HE6, 1ZDH
virus	12	1ZDI, 2BBV, 5MSF, 6MSF, 7MSF 1F8V, 1KNZ
TRAP	3	1C9S, 1GTF, 1GTN
SRP	4	1HQ1, 1JID, 1L9A, 1LNG
others	6	1DI2, 1EC6, 1FXL, 1G2E, 1KQ2 1URN

2.2 Protein-RNA interaction propensity

단백질의 interaction에는 해당 단백질 내의 잔기의 종류

와 잔기들의 구성 부위에 영향을 받는다. 본 논문에서는 이 두 가지 조건을 이용하여 단백질의 각 아미노산 별로 RNA와의 interaction 기대치를 계산한다.

우리의 이전 연구에서 단백질-RNA 간의 interaction 선호도를 *propensity*라는 값을 정의하여 계산하였다 [5]. 이 값은 1을 기준으로 1 보다 큰 경우 각각의 아미노산과 핵산 간에 높은 interaction 선호도가 있는 것이고, 1 보다 작은 경우는 낮은 선호도를 갖는 것이다. 그러나 이 값의 경우는 각각의 아미노산과 핵산간에 일반적인 interaction 성향을 구한 것이기 때문에 이 값만을 가지고 interaction 부위를 예측하는 것은 제한적일 수 밖에 없다. 이를 테면 잔기가 표면에 완전히 드러나 있는지 아니면 일부분만 드러나 있는지는 해당 잔기가 외부의 물질과 interaction 하는데 큰 영향을 끼치는 중요한 원인이 되지만 *propensity* 값만을 본다면 두 경우가 모두 동일한 값을 갖게 된다. 따라서 이번 연구에서는 기존 연구의 *propensity* 값과 노출된 정도에 따른 성향 값을 이용하여 interaction 기대치를 구하고 그 값을 이용해서 RNA와 interaction 후보지를 선정한다. 표 2는 우리의 기존 연구 [5]에서 계산한 각 아미노산의 *propensity value*를 보여주고 있다.

표 2 각 아미노산 별 Propensity 값

ARG	LYS	ASN	SER	THR	ASP	TYR	GLU	GLN	HIS
3.18	2.63	2	1.8	1.68	1.43	1.27	1.15	1.11	1
TRP	PHE	GLY	MET	CYS	PRO	LEU	ALA	ILE	VAL
0.65	0.48	0.34	0.31	0.28	0.17	0.15	0.13	0.11	0.02

2.3 노출 정도에 따른 interaction propensity

아미노산의 위치가 반영된 interaction 기대치를 얻기 위해 새로운 값인 노출 정도에 따른 interaction propensity값을 계산해야 한다. 여기에 사용되는 어플리케이션은 NACCESS로, NACCESS는 PDB 파일을 입력 받아 각 잔기와 원자의 accessibility를 계산하는 어플리케이션이다. Accessibility 값이 클수록 해당 잔기나 원자가 외부에 노출된 정도가 크다는 것을 의미한다 [6]. 본 논문에서는 51개 데이터에 대해 각각의 아미노산의 accessibility를 구하여 interaction 하는 아미노산과 그렇지 않은 아미노산의 개수를 세서 아미노산의 accessibility에 따른 interaction 비율을 계산했다 [표3].

모든 아미노산은 0~249의 accessibility를 찾으며 대체로 값이 클수록 interaction 하는 비율이 높은 경향을 띠지만 정확히 그렇지는 않다. 이를테면 210~219나 240~249의 아미노산은 높은 수준으로 노출 되어있지만, interaction은 제한적으로 일어난다. 가장 높은 비율로 interaction하는 accessibility대는 170~179로 이 수치대의 아미노산은 20%가 interaction을 하고 있다. 반면 접근성이 10 미만인 아미노산의 경우는 거의 RNA와의 interaction이 일어나지 않고 있다.

2.4 Interaction 기대치

각 아미노산의 Interaction 기대치는 아래 수식 (1)을 이용하여 계산한다.

$$E = k \cdot P \cdot EP \quad (1)$$

기대치 E 는 각 아미노산의 *propensity* 값 P 와 accessibility에 따른 interaction propensity EP 의 곱으로 얻는다. 여기서 k 는 기대치에 영향을 주는 상수로 2.95를 적용한다. 기대치를 계산하는 예를 들면, 175의 accessibility를 갖는 ARG의 interaction 기대치를 구하고자 한다면 $2.95 * 3.18 * 0.200 = 1.876$ 의 기대치를 갖게 되므로 51개 PDB 내의 모든 아미노산의 평균 기대치인 0.126

표 1 아미노산의 노출정도에 따른 propensity 값

접근성	총 잔기 수 (A)	Interaction 잔기 수 (B)	(B) / (A)
0 ~ 9	7769	33	0.004
10 ~ 19	2796	102	0.036
20 ~ 29	2085	99	0.047
30 ~ 39	2080	121	0.058
40 ~ 49	1784	67	0.038
50 ~ 59	1912	59	0.031
60 ~ 69	1767	78	0.044
70 ~ 79	1318	84	0.064
80 ~ 89	1357	56	0.041
90 ~ 99	1131	98	0.087
100 ~ 109	803	39	0.049
110 ~ 119	665	36	0.054
120 ~ 129	678	63	0.093
130 ~ 139	478	46	0.096
140 ~ 149	294	23	0.078
150 ~ 159	211	17	0.081
160 ~ 169	150	17	0.113
170 ~ 179	105	21	0.200
180 ~ 189	63	8	0.127
190 ~ 199	26	3	0.115
200 ~ 209	26	3	0.115
210 ~ 219	17	1	0.059
220 ~ 229	9	1	0.111
230 ~ 239	11	2	0.182
240 ~ 249	31	0	0.000
Total	27566	1077	0.039




그림 1 기대치를 얻기 위한 개괄적인 과정

과 비교하면 interaction 기대치가 상당히 높은 편이 된다. 그림 1은 기대치를 얻기 위한 전체적인 과정을 개략적으로 보여주고 있다.

3. 평가 및 결론

도출한 식을 이용하여 분석 데이터에 포함되지 않은 새로운 단백질-RNA 복합체 데이터를 이용해서 1A34, 1BY4, 2A8V를 대상으로 interaction 하는 아미노산을 예측해 보았다. 이 세 복합체는 이미 RNA와 interaction 하고 있는 것을 알고 있기 때문에, 단백질 부위만 따로 떼어서 각 아미노산의 기대 값을 구한 다음 실제 interaction 하는 아미노산과 비교 함으로써 기대치의 신뢰도를 측정할 수 있다.

그림 2는 단백질-RNA 복합체 1BY4를 RASMOOL을 이용하여 시각적으로 표현한 것이다. 청색으로 그려진 부분이 기대치가 0.240 이상인 부분이며 spacefill로 표시된 부분은 실제로 결합하는 부분이다.




그림 2 단백질과 RNA의 결합 예

황색은 RNA, 청색은 기대치 0.240 이상의 아미노산 Spacefill로 그려진 부분은 실제로 결합하는 아미노산 각 수치는 interaction 기대치를 의미함.

세 복합체는 총 820개의 아미노산으로 구성되어 있으며, 그 중 42개의 아미노산이 RNA와 interaction한다. Interaction 기대치가 0.240 이상인 경우를 interaction 할 가능성이 높은 아미노산으로 분류한다면 820개 중 223개의 아미노산이 interaction 할 가능성이 높은 아미노산으로 분류되고, 그 중 29개 아미노산이 실제로 interaction 하는 아미노산으로 판별되었다. 이 과정에서 전체 단백질의 25% 정도를 결합 후보자로 압축 할 수 있어 관련 연구에 도움을 줄 수 있을 것으로 기대된다. 낮은 기대치를 갖지만 실제로는 interaction하는 아미노산이 13개 있었는데, 그 이유는 실제 interaction은 잔기 단위로 일어나는 것이 아니기 때문에 해당 부근에 interaction이 있다면 인근 잔기들은 낮은 기대치를 갖더라도 interaction 하게 되는 경우가 있기 때문이다. 이러한 문제를 해결하기 위해서는 본 논문에서와 같이 단일 잔기 단위로 기대치를 계산하기보다는 구역 단위로 계산하여 interaction 후보지를 예측해야 하는데, 이것은 차후 개선 시킬 예정이며 보다 효과적인 결과가 기대된다. 또한 본 논문에서는 단백질-RNA interaction의 경우로 한정하여 접근하였지만, 우리의 접근 방식은 단백질-단백질 interaction이나 단백질-DNA interaction에도 유효한 접근 방식이므로 해당 복합체의 연구에도 쉽게 적용될 수 있다.

후기

본 연구는 정보통신부 정보통신 선도기반기술개발사업(과제 번호 01-PJ11-PG9-01BT00B-0012)의 지원에 의하여 이루어졌음.

참고문헌

- [1] David G. Levitt and Leonard J. Banaszak. POCKET: A computer graphics method for identifying and displaying protein cavities and their surrounding amino acids. *J. Mol. Graphics*, **10**, 229-234, 1992
- [2] <http://www.python.org>
- [3] H.M. Berman, J. Westbrook, Z. Feng, G. Gilliland, T.N. Bhat, H. Weissig, I.N. Shindyalov, P.E. Bourne. The Protein Data Bank. *Nucleic Acids Research*, **28**, 235-242, 2000.
- [4] S.F. Altschul, T.L. Madden, A.A. Schaffer, J. Zhang, Z. Zhang, W. Miller, and D.J. Lipman. Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Research*, **25**, 3389-3402, 1997
- [5] H. Kim, E. Jeong, S.-W. Lee and K. Han. Computational analysis of hydrogen bonds in protein-RNA complexes for interaction patterns. *FEBS Letters*, 2003 (in press)
- [6] <http://wolf.bms.umist.ac.uk/naccess>