

Antrinių baltymo struktūrų nuspėjimo metodų modifikavimo galimybės

Alvydas ŠPOKAS, Albertas TIMINSKAS (VGTU)
el. paštas: alvydas.spokas@fm.vtu.lt, timis@ibt.lt

1. Įvadas

Baltymai – tai biologiškai aktyvios molekulės, sudarytos iš įvairių amino rūgščių, susijungusių į ilga peptidinę grandinę. Biologinei funkcijai atliliki tokia amino rūgščių seką turi išgauti savitą erdinę struktūrą (1 pav.).

Baltymų erdinės struktūros sudarytos iš tam tikrų tarpinės (antrinės) struktūros elementų (H – alfa spiralė, S – beta klostė, C – jungiamieji fragmentai).

Dauguma baltymų savarankiškai sugeba susivynioti į reikiama erdinę globulę. Tai leidžia teigti, jog amino rūgščių sekoje yra užkoduota visa reikiama informacija apie baltymo molekulės erdinę struktūrą. Nuspėti iš karto tretinę baltymo struktūrą yra labai sudėtinga dėl per didelio spėjimų laisvės laipsnių skaičiaus, todėl stengiamasi tiksliai nuspėti tarpinę – antrinę – struktūrą siekiant palengvinti tretinės struktūros spėjimą. Teisingai iškodavus amino rūgščių sekoje slypinčią struktūros susidarymo informaciją, atsivertų didelės jos panaudojimo galimybės:

1. Tiksliai o svarbiausia greitai ir su minimaliom išlaidom nuspėti praktiškai bet kokios amino rūgščių sekos antrinę struktūrą. Nuspėjimo tikslumas bus apsprestas iškodavimo tikslumo.
2. Turima pakankamai tiksliai amino rūgščių sekos antrinė struktūra leistų nesunkiai prognozuoti (sumodeliuoti) šios sekos erdinę struktūrą.
3. Žinoma erdinė struktūra (molekulės vaizdas) suteikia daug reikšminės informacijos palengvinančios tolimesnius baltymų tyrimus.



1 pav. Erdinė baltymo struktūra. Atitinkamai išskirtos skirtinės baltymo antrinės struktūrinės būsenos.

4. Suprantamas balytymo molekulės erdinės struktūros susidarymo mechanizmas leistų konstruoti dirbtinius balytymus su norima (iš anksto žinoma) funkcija.

Šiuo metu ypač aktualūs balytymo antrinių struktūrų nuspėjimo metodai, kaip tarpinė grandis leidžianti ženkliai sumažinti laipsnių skaičių sprendžiant balytymu erdinės struktūros nuspėjimo uždavinius.

2. Nuspėjimo metodai

Gamtoje aptinkamu balytymu sudėtyje yra 20 skirtingų amino rūgščių, tačiau kiekvieno balytymo amino rūgščių sudėtis bei antrinių struktūrinų būsenų kiekis yra saviti. Vienos amino rūgštys balytymuose yra populiaresnės už kitas, be to amino rūgštys savitai pasiskirsto antrinių struktūrų būsenose. Pasinaudojant balytymu duomenų bazės stebėjimais yra išvertinamas kiekvienos amino rūgšties struktūriškumas (gebėjimas įtakoti tam tikros antrinės struktūrinės būsenos susidarymą).

$$I(S; P) = \ln \left(\frac{P(S|R)}{P(S)} \right) = \ln \left(\frac{f(S, R)}{f(R)} / \frac{f(S)}{f(N)} \right) = \ln \left(\frac{f(S, R)}{f(R)} \right) - \ln \left(\frac{f(S)}{f(N)} \right), \quad (1)$$

čia:

S – viena iš trijų struktūrinų būsenų (H , S arba C),

R – viena iš 20 amino rūgščių,

$P(S; R)$ – tikimybė, kad amino rūgštis R yra struktūrinėje būsenoje S ,

$P(S)$ – tikimybė aptikti struktūrinę būseną,

$f(S, R)$ – amino rūgšties dažnumas antrinės struktūros būsenoje,

$f(S)$ – struktūrinės būsenos dažnumas,

$f(R)$ – amino rūgšties dažnumas.

2.1. Fasman'o metodas

Struktūrinė informacija pati savaime nėra patikima dėl normavimo, todėl plačiau tai- komas struktūrinės informacijos pokytis (struktūriškumo matas), kuris parodo amino rūgšties vienos struktūrinės informacijos pranašumą prieš kitas.

$$I(S) = I(S; R) - I(\bar{S}; R) = \ln \left(\frac{f(S, R)}{f(\bar{S}, R)} \right) - \ln \left(\frac{f(S)}{f(\bar{S})} \right), \quad (2)$$

čia:

$I(S; R)$ – struktūrinė informacija susidaryti tam tikrai struktūrinei būsenai S ,

$I(\bar{S}; R)$ – struktūrinė informacija susidaryti kitoms struktūrinėms būsenoms (visoms išskyrus S).

Paremtas amino rūgščių struktūriškumo matais sukurtas vienas pirmųjų antrinių struktūrų nuspėjimo metodų – Fasman'o metodas. Šio metodo efektyvumas (tikslumas) siekia 50%, nors naudojamos struktūriškumo matų matricos dydis yra tik 3×20 (kiekviena iš 20 amino rūgščių gali būti vienoje iš 3 struktūrinų būsenų). Balytymo antrinių

struktūrinių būsenų nuspėjimo metodų tikslumas apskaičiuojamas išvertinant kiekvienos struktūrinės būsenos spėjimo tikslumą.

$$Q = \frac{Q_H + Q_S + Q_C}{3}, \quad (3)$$

čia Q_H, Q_S, Q_C – atitinkamų struktūrinių būsenų spėjimo tikslumai.

2.2. GOR metodai

Amino rūgščių struktūriškumo matai įtakoja vienas kitą, t.y. vienos amino rūgštis struktūriškumo matas dalinai apsprendžia kaimyninės amino rūgštis (kaimynės) struktūrinę būseną. Todėl GOR algoritmu parenti antrinių balytymo struktūrų nuspėjimo metodai išvertina ne tik centrinės (analizuojamoje pozicijoje esančios), bet ir kaimynių (po 8 i abi puses) struktūriškumo matus. Taigi (2) išraiška taikoma ir visiems kaimynams sumuojančių struktūriškumo matų įtakas.

$$I(\Delta S) = \sum_{|n|=1}^8 (I(S; R_n) - I(\bar{S}; R_n)) = \sum_{|n|=1}^8 \left(\ln \left(\frac{f(S, R_n)}{f(\bar{S}, R_n)} \right) - \ln \left(\frac{f(S)}{f(\bar{S})} \right) \right), \quad (4)$$

čia:

R_n – kaimyninė, per n pozicijų nuo centrinės nutolusi amino rūgštis,

$I(S; R_n)$ – kaimyninės amino rūgštis struktūriškumo matas.

Tokiu atveju metode naudojamų struktūriškumo matų matricos dydis yra $3 \times 20 \times 17$, o metodo tikslumas siekia 63%.

Kaimyninės amino rūgštis įtaka centrinei struktūrinei būsenai priklauso nuo centrinės bei kaimyninės amino rūgščių prigimties, todėl (4) išraiška GOR metodo trečiojoje versijoje (GOR III) naudojama žinomos prigimties amino rūgštis struktūrinei būsenai nusakyti.

$$\begin{aligned} I(\Delta S) &= \sum_{|n|=1}^8 (I(S; R_n|R) - I(\bar{S}; R_n|R)) \\ &= \sum_{|n|=1}^8 \left(\ln \left(\frac{f(S, R_n, R)}{f(\bar{S}, R_n, R)} \right) - \ln \left(\frac{f(S, R)}{f(\bar{S}, R)} \right) \right). \end{aligned} \quad (5)$$

Tokiu būdu metode naudojamų struktūriškumo matų matricos dydis padidėja iki $20 \times 3 \times 20 \times 16$, o metodo tikslumas siekia 64%.

2.3. Metodo išplėtimas

GOR metodo autoriai daug dėmesio skiria kaimynių struktūriškumo matams išvertinti, tačiau nekreipiamas dėmesys į susidarančių antrinių struktūrų tarpusavio sąveikas. Balytymo

sintezės metu susidarantys antrinių struktūrinių būsenų komponentai sąveikauja tarpusavyje ir neretai tolimesni struktūrinių būsenų pokyčiai apsprrendžiami ne kaimynų prigimtis o jų struktūrinių būsenų susidarymas (struktūrinė būsena įtakoja struktūrinei būsenai). I (5) išraišką ištraukus kaimynės struktūrinę būseną, gauname:

$$\begin{aligned} I(\Delta S, \Delta S_n) &= \sum_{|n|=1}^8 (I(S; R_n | S_n) - I(\bar{S}; R_n | S_n)) \\ &= \sum_{|n|=1}^8 \left(\ln \left(\frac{f(S, R_n, S_n)}{f(\bar{S}, R_n, S_n)} \right) - \ln \left(\frac{f(S, S_n)}{f(\bar{S}, S_n)} \right) \right). \end{aligned} \quad (6)$$

Taip peržiūrint visas kaimynių struktūras, įvertinama centrinės amino rūgšties struktūrinės būsenos susidarymo informacija.

$$I(\Delta S) = \sum_{i=1}^3 I(\Delta S, \Delta S_n^i) = \sum_{|n|=1}^8 \sum_{i=1}^3 \left(\ln \left(\frac{f(S, R_n, S_n^i)}{f(\bar{S}, R_n, S_n^i)} \right) - \ln \left(\frac{f(S, S_n^i)}{f(\bar{S}, S_n^i)} \right) \right). \quad (7)$$

Šios lygties sprendimo variantai yra keli. Dabar pateikiamas supaprastintas sprendimo variantas, kuris buvo išbandytas praktiškai nuspėjant baltymo antrinę struktūrą. Struktūrinių būsenų nuspėjimo metu analizuojamos iš karto dvielės (centrinės ir kaimyninės) struktūrinių būsenų susidarymas, todėl uždavinio sprendimo metu daroma prieilaida:

$$I(\Delta S) = \sum_{i=1}^3 I(\Delta S; \Delta S_n^i), \quad (8)$$

kurios dėka (7) išraiška tampa ekvivalentiška (5). Tokiu būdu įvertinus centrinės amino rūgšties struktūrinės būsenos susidarymą, yra įvertinama kaimynių struktūrinių būsenų susidarymas remiantis centrinės ir kaimyninės struktūrinių būsenų populiarumu.

$$I(\Delta S_n) = I(\Delta S_0) \times P(S_0, S_n | R, R_n), \quad (9)$$

čia $P(S_0, S_n | R, R_n)$ – tikimybė aptikti struktūrinių būsenų kombinaciją (1 iš 9), prie tam tikros amino rūgščių kombinacijos.

Bendru atveju kiekvieno baltymo sekos taško galimas struktūrinis būvis nusakomas remiantis dvielėjų komponentų rezultatais:

- 1) centrinės ir kaimynių struktūriškumo matų įtakos,
- 2) centrinės ir kaimynių struktūrinių būsenų kombinacijų populiarumu.

Taigi ir bendras kiekvieno sekos taško struktūrinis būvis nusakomas dvielėjų komponenčių pagalba.

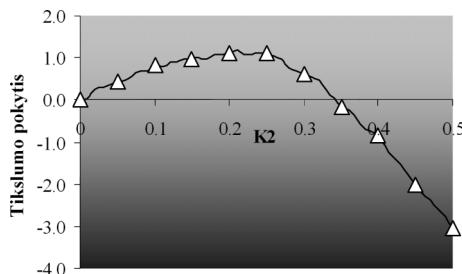
$$I(\Delta S) = I(\Delta S_0) \times K_1 + I(\Delta S_n) \times K_2. \quad (10)$$

2.4. Sprendimas

Varijuojant komponenčių svorio koeficientais kaimynių struktūrinių būsenų įtakos įvedimas leido klasikinio GOR metodo tikslumą padidinti apie 1% (2 pav.).

Gautas metodo tikslumo padidėjimas yra reikšmingas, kadangi metode naudojamų struktūrų matu matricos dydis padidėjo nežymiai, lyginant su GOR metodo evoliucijos metu gautais tikslumo bei matricos dydžio pokyčiais (1 lentelė).

Kitas (6) lygties sprendimo variantas yra subtilusnis ir jis nėra išbandytas praktiškai. Siūloma, pagal (6) lygtį analizuoti visas įmanomas struktūrinių būsenų kombinacijas, kiekvienai kaimynei ir iš gautų duomenų (3 pav.) parinkti optimalią centrinės struktūrinės būseną.



2 pav. Kaimyninių struktūrinių būsenų įvertinimo rezultatai, priklausomybėje nuo suteikto jiems svorio K_2 ($K_1 + K_2 = 1$).

1 lentelė. Antrinių baltymo struktūrų nuspėjimo metodų tikslumo pokytis

Eil. Nr.	Metodai	Parametru skaičius	Parametru pokytis kartais	Tikslumo pokytis
1	GOR I	$20 \times 17 \times 3$	1	0
2	GOR III	$20 \times 17 \times 3 \times 20$	20	0,5
3	GOR Is	$20 \times 3 \times 17 \times 3$	3	1

- a) 87654321012...
MADFRTIJKLML...
 $H * * * * * * H * * * * \Rightarrow N81$
 $H * * * * * * S * * * * \Rightarrow N82$
 $H * * * * * * C * * * * \Rightarrow N83$
 $S * * * * * * H * * * * \Rightarrow N84$
 $S * * * * * * S * * * * \Rightarrow N85$
 $* * * * * * * * * * *$
 $*H * * * * * H * * * * \Rightarrow N71$
 $* * * * * * * * * * *$
 $* * * * * * H H * * * * \Rightarrow N11$
 $* * * * * * * * * * *$
- b) 87654321012...
MADFRTIJKLML...
 $S C H H S S C' N16$
 $* S H H C C S C' N26$
 $* * S H H C C S C' N33$
 $* * * C S H H H S C' N49$
 $* * * * C C H S S S C' N59$

3 pav. Optimalių struktūrinių būsenų kombinacijų parinkimas. a) Įvertinamas kiekvienos struktūrinių būsenų poros populiarumas, b) išrenkamos populiariausios poros ir atliekama optimizacija.

Pagal pasirinktą centrinę struktūrinę būseną atitinkamai parenkamos optimalios kaimynių struktūrinės būsenos ir gaunami lokalių 17-tukų struktūrių būsenų spėjimai. Kiekvienas sekos taškas nusakomas 17 kartų, iš kurių turi būti parenkamas optimalus. Kadangi struktūrinės būsenos parinkimas turi grižtamajį ryšį (itakoja prieš tai pasirinktų struktūrių būsenų pokyčius), tikslinga naudoti iteracinių optimalios struktūrinės būsenos nusakymą.

Be abejo, galima ši optimizavimo uždavinį spręsti be tarpinių (lokaliai optimaliu fragmētu) nusakymų, tačiau tokiu atveju pernelyg didelis laisvės laipsnių skaičius labai apsunkintų uždavinio sprendimą.

3. Išvados

Sékmingai pritaikytas vienas iš galimų baltymo antrinių struktūrų nuspėjimo metodo GOR išplėtimas panaudojant struktūrių būsenų tarpusavio sąveikas. Gauti rezultatai rodo, kad struktūrių būsenų sąveikos įvertinimas yra reikšmingas ir suteikia papildomos informacijos apie baltymo antrinių struktūrų susidarymo ypatybes.

Literatūra

- [1] *Bioinformatics: Sequence, Structure, and Databanks*, Oxford Press (2000).
- [2] J. Garnier, D.J. Osguthorpe, B. Robson, *J. Mol. Biol.*, **120**, 97–20 (1978).
- [3] M. Ouali, King RD, *Protein Sie* 2000, **9**(6), 9998–99.
- [4] J. Garnier, D.J. Osguthorpe, B. Robson, *Methods Enzymol.*, **266**, 541–53 (1996).
- [5] J. Westbrook, Z. Feng, S. Jain, T.N. Bhat, N. Thanki, V. Ravichandran, G.L. Gilliland, W. Bluhm, H. Weissig, D.S. Greer, P.E. Bourne, H.M. Berman, *Nucleic Acids Res.*, **30**(1), 245–48 (2002).
- [6] R.D. King, M.J.E. Sternberg, *Protein Sci.*, **5**(11), 2298–10 (1996).
- [7] <http://www.rcsb.org/pdb/>

Modify possibilities of the secondary structures prediction method

A. Špokas, A. Timinskas

It was analyzed dependence of the average accuracy of secondary protein structure prediction on various GOR algorithm modifications. In essence new modification has expanded informational parameter set by taking into account secondary structure of neighboring amino acid. The accuracy of the method with this modification increases almost for 1 percent. This increase in accuracy is quite significant, as the amount of informational parameters increases not much.