

**UNIVERZITA SV. CYRILA A METODA V TRNAVE**

Fakulta prírodných vied



Štefan Janeček

**BIOINFORMATIKA PROTEÍNOV**

Trnava 2020

Autor: Doc. Ing. Štefan Janeček, DrSc.

Publikácia bola schválená edičnou radou Univerzity sv. Cyrila a Metoda v Trnave a vedením Fakulty prírodných vied Univerzity sv. Cyrila a Metoda v Trnave ako učebné texty pre študentov vysokých škôl.

© Univerzita sv. Cyrila a Metoda v Trnave

© Doc. Ing. Štefan Janeček, DrSc.

Všetky práva vyhradené.

Vydala: Univerzita sv. Cyrila a Metoda v Trnave, 2020.

Vydanie: prvé.

Web: [http://fpv.ucm.sk/images/ucebne\\_texty/Bioinformatika\\_proteinov.pdf](http://fpv.ucm.sk/images/ucebne_texty/Bioinformatika_proteinov.pdf)

ISBN 978-80-572-0085-7

## Predstavanie

Čo je to bioinformatika? Čím sa zaoberá? Čomu sa primárne venuje a čo ponúka? Aký je jej zmysel?

Bioinformatika je vedná disciplína na rozhraní viacerých vedných odborov, ktoré sa vzájomne prelínajú. Ide najmä o prienik matematických odborov a tzv. odborov „Life Sciences“, t.j. vied o živej prírode. Je to teda informatika a aplikovaná matematika na jednej strane, doplnené na strane druhej molekulárnu biológiou, genetikou, genomikou, proteomikou, biochémiou, prípadne mikrobiológiou a ďalšími, ako napr. výpočtová biológia, systémová biológia a teoretická biológia. V podstate ide o riešenie biologických problémov na molekulárnej úrovni, ale samotná práca sa vykonáva spôsobom *in silico*, t.j. ani *in vivo* (priamo na živých organizmoch), ani *in vitro* (v laboratóriu; „v skúšobnej“), ale v laboratóriu „virtuálnom“ – na počítači.

Pri bioinformatike ide o často o sofistikované získavanie, detailnú analýzu, relevantnú vizualizáciu a správnu interpretáciu zväčša mimoriadne objemných súborov biologických dát, ktoré predstavujú nukleotidové a aminokyselinové sekvencie DNA a RNA, resp. proteínov, ako aj terciárne štruktúry týchto biomakromolekúl, hlavne proteínov. V širšom ponímaní patrí do bioinformatiky aj štúdium údajov o aktivite a expresii génov, pričom významnou súčasťou bioinformatiky je predikcia štruktúr proteínov a ich funkcií, vyúsťujúca vo formulovaní záverov súvisiacich s evolúciou. Výsledky bioinformatiky sú využívané experimenálne orientovaným výskumom, ale aj praxou, napr. v medicíne a polícií. V ideálnom prípade výsledky získané bioinformatickými, t.j. *in silico* prístupmi môžu pomáhať v experimentálnom výskume tým, že naznačujú smer jeho ďalšieho postupu, čím jednoznačne prispievajú k šetreniu finančných zdrojov a skráteniu času potrebného pre dosiahnutie stanovených cieľov.

Ako je zrejmé z názvu, tento učebný text je zameraný na bioinformatické prístupy k štúdiu proteínov.

## **Obsah**

1.	Počiatky genómových sekvenačných projektov .....	3
2.	GenBank a UniProt – základné sekvenčné databázy .....	12
3.	Základy bioinformatickej – <i>in silico</i> – analýzy proteínov .....	27
4.	HCA – metóda analýzy hydrofóbnych klastrov .....	42
5.	BLAST – nátroj na vyhľadávanie sekvenčných podobností .....	51
6.	PDB, modelovanie a porovnávanie štruktúr proteínov .....	62
7.	Praktické úlohy a cvičenia .....	77

## **1. Počiatky genómových sekvenačných projektov**

Počiatky genómových sekvenačných projektov spadajú do druhej polovice 90. rokov minulého storočia. Išlo, resp. ide o projekty zamerané na získanie nukleotidovej sekvencie kompletného genómu daného organizmu. Zisk tejto informácie je v podstate nevyhnutnou, aj keď nie jedinou a dostačujúcou podmienkou, ktorá umožní kompletné porozumenie biológie organizmu.

Sekvenovaniu kompletných genómov organizmov predchádzalo sekvenovanie jednotlivých génov a väčších úsekov DNA, ale potom najmä genómov vírusov a organel. Prvým kompletne sekvenovaným bol bakteriofág  $\varphi$ X174 v roku 1977 s 5 386 bázovými párami (bp). Pre porovnanie: prvý kompletne osekvenovaný, samostatne existujúci organizmus, ktorým bola v roku 1995 baktéria *Haemophilus influenzae*, mal veľkosť genómu 1 830 837 bp (t.j. ~1,83 Mbp) a 1 743 génov kódujúcich proteíny.

Preto, aby sa mohlo vôbec pristúpiť k začiatiu sekvenovania kompletných genómov organizmov, bolo potrebné zhromaždiť nemalé finančné prostriedky a dať dohromady aj obrovský ľudský potenciál. Jedným z najvýznamnejších ľudí, ktorý sa pričinil o spustenie a úspech genómových sekvenačných projektov, bol americký biotechnológ a vizionár Craig Venter, zakladateľ viacerých inštitúcií (napr. The Institute for Genomic Research, TIGR; ale aj iné), v ktorých sa úspešne sekvenovali genómy. Okrem financií a ľudského potenciálu boli súčasťou rozvoja sekvenovania genómov aj pokroky v prístupoch a prístrojovom vybavení v oblasti „Life Sciences“, najmä molekulárnej biológie, v zdokonaľovaní výpočtovej techniky a programových nástrojov, ako aj objavenie a rozmach internetu.

Najskôr sa samozrejme pristúpilo k sekvenovaniu prokaryotov, pretože majú menší jednoduchší genóm v porovnaní s eukaryotmi. Tiež boli medzi prvými sekvenované rôzne modelové a široko využívané mikroorganizmy, ako napr. *Bacillus subtilis* a *Escherichia coli*, ale aj rôzne patogény, ako samotný prvý osekvenovaný genóm *Haemophilus influenzae* (rôzne infekcie až sepsy), ďalej napr. *Helicobacter pylori* (gastritidy), *Borrelia burgdorferi* (lymská borelióza), *Mycobacterium tuberculosis* (tuberkulóza), *Treponema pallidum* (syfilis), *Vibrio cholerae* (cholera), *Yersinia pestis* (mor) a iné. Ako predstaviteľ

minimalistického genómu bola ešte v roku 1995 osekvenovaná *Mycoplasma genitalium* s veľkosťou genómu 580 070 bp (t.j. 0,58 Mbp) a iba 470 génnimi.

Ďalším nemenej významným úspechom genómových sekvenačných projektov bolo definitívne potvrdenie troch domén života v roku 1996 – konkrétnie domény *Archaea* – po osekvenovaní prvého archeónu *Methanococcus jannaschii*, ktorý produkuje metán. Archaebaktérie ako samostatnú vývojovú vetvu prokaryotov – odlišnú od „pravých“ baktérií – objavil a popísal už v roku 1977 americký mikrobiológ Carl Woese. Ďalším v poradí bol v roku 1997 sírany redukujúci archeón *Archaeoglobus fulgidus*.

Bežný prokaryotický genóm má v hrubom približení veľkosť okolo 2 Mbp a obsahuje cca 2 000 génnov; samozrejme to je iba veľmi približný, aj keď viac-menej reálny odhad, pre ktorý existujú výnimky nad aj pod ním. Prvou osekvenovanou hubou – eukaryot, ale stále mikroorganizmus – bola v roku 1996 kvasinka *Saccharomyces cerevisiae* s 5 885 génnimi a 12,07 Mbp. U eukaryotických organizmov pri narastajúcej veľkosti ich genómov vo vzťahu k menej adekvátnemu nárastu počtu ich génnov treba uvažovať ich exón-intrónovú organizáciu s nekódujúcimi oblastami. V tomto smere je mimoriadne zaujímavý genóm človeka, publikovaný prvý raz v roku 2001, ktorého veľkosť je ~2,91 Gbp, pričom dolný odhad počtu génnov, ktoré kódujú proteíny, bol stanovený na hranici 30 000. Pozoruhodné je, že ak by bol počet 30 tisíc génnov človeka teoreticky vztiahnutý na prokaryotický genóm (2 Mbp / 2000 génnov), jeho veľkosť by mala byť iba asi 30 Mbp.

Ilustrácie prvých kompletných sekvenačných projektov:



Fleischmann RD, ... & Venter JC (1995) Whole-genome random sequencing and assembly of *Haemophilus influenzae* Rd. *Science* **269**: 496–512.  
<https://doi.org/10.1126/science.7542800>




Fraser CM, ... & Venter JC (1995) The minimal gene complement of *Mycoplasma genitalium*. *Science* **270**: 397–403.  
<https://doi.org/10.1126/science.270.5235.397>




Bult CJ, ... & Venter JC (1996) Complete genome sequence of the methanogenic archaeon, *Methanococcus jannaschii*. *Science* **273**: 1058–1073.  
<https://doi.org/10.1126/science.273.5278.1058>



Goffeau A, ... & Oliver SG (1996) Life with 6000 genes. *Science* **274**: 546, 563–567.  
<https://doi.org/10.1126/science.274.5287.546>



C. elegans Sequencing Consortium (1998) Genome sequence of the nematode *C. elegans*: a platform for investigating biology. *Science* **282**: 2012–2018.  
<https://doi.org/10.1126/science.282.5396.2012>



Arabidopsis Genome Initiative (2000) Analysis of the genome sequence of the flowering plant *Arabidopsis thaliana*. *Nature* **408**: 796–815.  
<https://doi.org/10.1038/35048692>



Gardner MJ, ... & Barrell B (2002) Genome sequence of the human malaria parasite *Plasmodium falciparum*. *Nature* **419**: 498–511.  
<https://doi.org/10.1038/nature01097>



Chimpanzee Sequencing and Analysis Consortium (2005) Initial sequence of the chimpanzee genome and comparison with the human genome. *Nature* **437**: 69–87. <https://doi.org/10.1038/nature04072>



Warren WC, ... & Wilson RK (2008) Genome analysis of the platypus reveals unique signatures of evolution. *Nature* **453**: 175–183.  
<https://doi.org/10.1038/nature06936>

Publikácia o sekvenovaní genómu včely je ilustráciou zapojenia množstva autorov z 90 pracovísk celého sveta; nižšie je rozpísaná aj ich vzájomná deľba práce.



Honeybee Genome Sequencing Consortium (2006) Insights into social insects from the genome of the honeybee *Apis mellifera*. *Nature* **443**: 931-949.  
<https://doi.org/10.1038/nature05260>

### ***The Honeybee Genome Sequencing Consortium***

**Overall project leadership:** George M. Weinstock<sup>1,2</sup>, Gene E. Robinson<sup>7,9,13,14</sup>

**Principal investigators:** Richard A. Gibbs<sup>1,2</sup>, George M. Weinstock<sup>1,2</sup>

**Community coordination:** George M. Weinstock (leader)<sup>1,2</sup>, Gene E. Robinson (leader)<sup>7,9,13,14</sup>, Kim C. Worley (leader)<sup>1,2</sup>, Jay D. Evans<sup>4</sup>, Ryszard Maleszka<sup>6</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Daniel B. Weaver<sup>16</sup>

**Annotation section leaders:** Martin Beye<sup>17</sup>, Peer Bork<sup>18,19</sup>, Christine G. Elsik<sup>20</sup>, Jay D. Evans<sup>4</sup>, Klaus Hartfelder<sup>25</sup>, Greg J. Hunt<sup>27</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Gene E. Robinson<sup>7,9,13,14</sup>, Ryszard Maleszka<sup>6</sup>, George M. Weinstock<sup>1,2</sup>, Kim C. Worley<sup>1,2</sup>, Evgeny M. Zdobnov<sup>18,28</sup>

**Caste development and reproduction:** Klaus Hartfelder (leader)<sup>25</sup>, Gro V. Amdam<sup>29</sup>, Márcia M. G. Bitondi<sup>26</sup>, Anita M. Collins<sup>4</sup>, Alexandre S. Cristino<sup>30</sup>, Jay D. Evans<sup>4</sup>, H. Michael G. Lattorff<sup>31</sup>, Carlos H. Lobo<sup>24</sup>, Robin F. A. Moritz<sup>31</sup>, Francis M. F. Nunes<sup>24</sup>, Robert E. Page Jr<sup>29</sup>, Zilá L. P. Simões<sup>26</sup>, Diana Wheeler<sup>32</sup>

**EST sequencing:** Piero Carninci (leader)<sup>33</sup>, Shiro Fukuda<sup>33</sup>, Yoshihide Hayashizaki<sup>33</sup>, Chikatoshi Kai<sup>33</sup>, Jun Kawai<sup>33</sup>, Naoko Sakazume<sup>33</sup>, Daisuke Sasaki<sup>33</sup>, Michihira Tagami<sup>33</sup>

**Brain and behaviour:** Ryszard Maleszka (leader)<sup>6</sup>, Gro V. Amdam<sup>29</sup>, Stefan Albert<sup>34</sup>, Geert Baggerman<sup>35</sup>, Kyle T. Beggs<sup>37</sup>, Guy Bloch<sup>38</sup>, Giuseppe Cazzamali<sup>41</sup>, Mira Cohen<sup>38</sup>, Mark David Drapeau<sup>42</sup>, Dorothea Eisenhardt<sup>43</sup>, Christine Emore<sup>27</sup>, Michael A. Ewing<sup>15</sup>, Susan E. Fahrbach<sup>48</sup>, Sylvain Forêt<sup>6</sup>,

Cornelis J. P. Grimmelikhuijzen<sup>41</sup>, Frank Hauser<sup>41</sup>, Amanda B. Hummon<sup>15</sup>, Greg J. Hunt<sup>27</sup>, Jurgen Huybrechts<sup>35</sup>, Andrew K. Jones<sup>44</sup>, Tatsuhiko Kadowaki<sup>55</sup>, Noam Kaplan<sup>40</sup>, Robert Kucharski<sup>6</sup>, Gérard Leboulle<sup>43</sup>, Michal Linial<sup>39,40</sup>, J. Troy Littleton<sup>45</sup>, Alison R. Mercer<sup>37</sup>, Robert E. Page Jr<sup>29</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Gene E. Robinson<sup>7,9,13,14</sup>, Timothy A. Richmond<sup>15</sup>, Sandra L. Rodriguez-Zas<sup>12</sup>, Elad B. Rubin<sup>38</sup>, David B. Sattelle<sup>44</sup>, David Schlipalius<sup>27</sup>, Liliane Schoofs<sup>35</sup>, Yair Shemesh<sup>38</sup>, Jonathan V. Sweedler<sup>13,15</sup>, Rodrigo Velarde<sup>7</sup>, Peter Verleyen<sup>35</sup>, Evy Vierstraete<sup>35</sup>, Michael R. Williamson<sup>41</sup>

**Development and metabolism:** Martin Beye (leader)<sup>17</sup>, Seth A. Ament<sup>13</sup>, Susan J. Brown<sup>50</sup>, Miguel Corona<sup>7</sup>, Peter K. Dearden<sup>36</sup>, W. Augustine Dunn<sup>52</sup>, Michelle M. Elekonich<sup>53</sup>, Christine G. Elsik<sup>20</sup>, Sylvain Forêt<sup>6</sup>, Tomoko Fujiyuki<sup>54</sup>, Irene Gattermeier<sup>17</sup>, Tanja Gempe<sup>17</sup>, Martin Hasselmann<sup>17</sup>, Tatsuhiko Kadowaki<sup>55</sup>, Eriko Kage<sup>54</sup>, Azusa Kamikouchi<sup>54</sup>, Takeo Kubo<sup>54</sup>, Robert Kucharski<sup>6</sup>, Takekazu Kunieda<sup>54</sup>, Marcé Lorenzen<sup>49</sup>, Ryszard Maleszka<sup>6</sup>, Natalia V. Milshina<sup>20</sup>, Mizue Morioka<sup>54</sup>, Kazuaki Ohashi<sup>54</sup>, Ross Overbeek<sup>57</sup>, Robert E. Page Jr<sup>29</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Gene E. Robinson<sup>7,9,13,14</sup>, Christian A. Ross<sup>53</sup>, Morten Schioett<sup>17</sup>, Teresa Shippy<sup>51</sup>, Hideaki Takeuchi<sup>54</sup>, Amy L. Toth<sup>14</sup>, Judith H. Willis<sup>52</sup>, Megan J. Wilson<sup>36</sup>

**Comparative and evolutionary analysis:** Hugh M. Robertson (leader)<sup>7,9,13,14</sup>, Evgeny M. Zdobnov (leader)<sup>18,28</sup>, Peer Bork<sup>18,19</sup>, Christine G. Elsik<sup>20</sup>, Karl H. J. Gordon<sup>46</sup>, Ivica Letunic<sup>18</sup>

**Funding agency management:** Kevin Hackett<sup>5</sup>, Jane Peterson<sup>58</sup>, Adam Felsenfeld<sup>58</sup>, Mark Guyer<sup>58</sup>

**Physical and genetic mapping:** Michel Solignac (leader)<sup>56</sup>, Richa Agarwala<sup>59</sup>, Jean Marie Cornuet<sup>60</sup>, Christine G. Elsik<sup>20</sup>, Christine Emore<sup>27</sup>, Greg J. Hunt<sup>27</sup>, Monique Monnerot<sup>56</sup>, Florence Mougel<sup>56</sup>, Justin T. Reese<sup>20</sup>, David Schlipalius<sup>27</sup>, Dominique Vautrin<sup>56</sup>, Daniel B. Weaver<sup>16</sup>

**Ribosomal RNA genes and related retrotransposable elements:** Joseph J. Gillespie (leader)<sup>21,62</sup>, Jamie J. Cannone<sup>61</sup>, Robin R. Gutell<sup>61</sup>, J. Spencer Johnston<sup>21</sup>

**Gene prediction and consensus gene set:** Christine G. Elsik (leader)<sup>20</sup>, Giuseppe Cazzamali<sup>41</sup>, Michael B. Eisen<sup>63,64</sup>, Cornelis J. P. Grimmelikhuijzen<sup>41</sup>, Frank Hauser<sup>41</sup>, Amanda B. Hummon<sup>15</sup>, Venky N. Iyer<sup>63</sup>, Vivek Iyer<sup>65</sup>, Peter Kosarev<sup>66</sup>, Aaron J. Mackey<sup>67</sup>, Ryszard Maleszka<sup>6</sup>, Justin T. Reese<sup>20</sup>, Timothy A. Richmond<sup>15</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Victor Solovyev<sup>68</sup>, Alexandre Souvorov<sup>59</sup>, Jonathan V. Sweedler<sup>13,15</sup>, George M. Weinstock<sup>1,2</sup>, Michael R. Williamson<sup>41</sup>, Evgeny M. Zdobnov<sup>18,28</sup>

**Honeybee disease and immunity:** Jay D. Evans (leader)<sup>4</sup>, Katherine A. Aronstein<sup>69</sup>, Katarina Bilikova<sup>70</sup>, Yan Ping Chen<sup>4</sup>, Andrew G. Clark<sup>72</sup>, Laura I. Decanini<sup>4</sup>, William M. Gelbart<sup>73</sup>, Charles Hetru<sup>74</sup>, Dan Hultmark<sup>75</sup>, Jean-Luc Imler<sup>74</sup>, Haobo Jiang<sup>76</sup>, Michael Kanost<sup>51</sup>, Kiyoshi Kimura<sup>77</sup>, Brian P. Lazzaro<sup>71</sup>, Dawn L. Lopez<sup>4</sup>, Jozef Simuth<sup>70</sup>, Graham J. Thompson<sup>78</sup>, Zhen Zou<sup>76</sup>

**BAC/fosmid library construction and analysis:** Pieter De Jong (leader)<sup>79</sup>, Erica Sodergren (leader)<sup>1,2</sup>, Miklós Csürös<sup>87</sup>, Aleksandar Milosavljevic<sup>1,2</sup>, J.

Spencer Johnston<sup>21</sup>, Kazutoyo Osoegawa<sup>79</sup>, Stephen Richards<sup>1,2</sup>, Chung-Li Shu<sup>79</sup>, George M. Weinstock<sup>1,2</sup>

**G1C content:** Christine G. Elsik (leader)<sup>20</sup>, Laurent Duret<sup>80</sup>, Eran Elhaik<sup>23</sup>, Dan Graur<sup>23</sup>, Justin T. Reese<sup>20</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>

**Transposable elements:** Hugh M. Robertson (leader)<sup>7,9,13,14</sup>, Christine G. Elsik<sup>20</sup>

**Gene regulation including miRNA and RNAi:** Ryszard Maleszka (leader)<sup>6</sup>, Daniel B. Weaver (leader)<sup>16</sup>, Gro V. Amdam<sup>29</sup>, Juan M. Anzola<sup>20</sup>, Kathryn S. Campbell<sup>73</sup>, Kevin L. Childs<sup>20</sup>, Derek Collinge<sup>46</sup>, Madeline A. Crosby<sup>73</sup>, C. Michael Dickens<sup>20</sup>, Christine G. Elsik<sup>20</sup>, Karl H. J. Gordon<sup>46</sup>, L. Sian Grametes<sup>73</sup>, Christina M. Grozinger<sup>81</sup>, Peter L. Jones<sup>9</sup>, Mireia Jordà<sup>89</sup>, Xu Ling<sup>8</sup>, Beverly B. Matthews<sup>73</sup>, Jonathan Miller<sup>1,3</sup>, Natalia V. Milshina<sup>20</sup>, Craig Mizzen<sup>17</sup>, Miguel A. Peinado<sup>89</sup>, Justin T. Reese<sup>20</sup>, Jeffrey G. Reid<sup>3,22</sup>, Hugh M. Robertson<sup>7,9,13,14</sup>, Gene E. Robinson<sup>7,9,13,14</sup>, Susan M. Russo<sup>73</sup>, Andrew J. Schroeder<sup>73</sup>, Susan E. St Pierre<sup>73</sup>, Ying Wang<sup>9</sup>, Pinglei Zhou<sup>73</sup>

**Superscaffold assembly:** Hugh M. Robertson (leader)<sup>7,9,13,14</sup>, Richa Agarwala<sup>59</sup>, Christine G. Elsik<sup>20</sup>, Natalia V. Milshina<sup>20</sup>, Justin T. Reese<sup>20</sup>, Daniel B. Weaver<sup>16</sup>

**Data management:** Kim C. Worley (leader)<sup>1,2</sup>, Kevin L. Childs<sup>20</sup>, C. Michael Dickens<sup>20</sup>, Christine G. Elsik<sup>20</sup>, William M. Gelbart<sup>73</sup>, Huaiyang Jiang<sup>1,2</sup>, Paul Kitts<sup>59</sup>, Natalia V. Milshina<sup>20</sup>, Justin T. Reese<sup>20</sup>, Barbara Ruef<sup>59</sup>, Susan M. Russo<sup>73</sup>, Anand Venkatraman<sup>20</sup>, George M. Weinstock<sup>1,2</sup>, Lan Zhang<sup>1,2</sup>, Pinglei Zhou<sup>69</sup>

**Chromosome structure:** J. Spencer Johnston (leader)<sup>21</sup>, Gildardo Aquino-Perez<sup>21</sup>, Jean Marie Cornuet<sup>60</sup>, Monique Monnerot<sup>56</sup>, Michel Solignac<sup>56</sup>, Dominique Vautrin<sup>56</sup>

**Population genetics and SNPs:** Charles W. Whitfield (leader)<sup>7,13,14</sup>, Susanta K. Behura<sup>7</sup>, Stewart H. Berlocher<sup>7,14</sup>, Andrew G. Clark<sup>72</sup>, Richard A. Gibbs<sup>1,2</sup>, J. Spencer Johnston<sup>21</sup>, Walter S. Sheppard<sup>82</sup>, Deborah R. Smith<sup>83</sup>, Andrew V. Suarez<sup>7,11</sup>, Neil D. Tsutsui<sup>84</sup>, Daniel B. Weaver<sup>16</sup>, Xuehong Wei<sup>1,2</sup>, David Wheeler<sup>1,2</sup>

**Genome assembly:** George M. Weinstock (leader)<sup>1,2</sup>, Kim C. Worley (leader)<sup>1,2</sup>, Paul Havlak<sup>1,2</sup>, Bingshan Li<sup>1,2</sup>, Yue Liu<sup>1,2</sup>, Erica Sodergren<sup>1,2</sup>, Lan Zhang<sup>1,2</sup>

**(A+T)-rich DNA generation:** Martin Beye (leader)<sup>17</sup>, Martin Hasselmann<sup>17</sup>, Angela Jolivet<sup>1,2</sup>, Sandra Lee<sup>1,2</sup>, Lynne V. Nazareth<sup>1,2</sup>, Ling-Ling Pu<sup>1,2</sup>, Rachel Thorn<sup>1,2</sup>, George M. Weinstock<sup>1,2</sup>

**Tiling arrays:** Viktor Stolc (leader)<sup>85</sup>, Gene E. Robinson (leader)<sup>7,9,13,14</sup>, Ryszard Maleszka<sup>6</sup>, Thomas Newman<sup>7</sup>, Manoj Samanta<sup>85,86</sup>, Waraporn A. Tongprasit<sup>85</sup>

**Anti-xenobiotic defence mechanisms:** Katherine A. Aronstein (leader)<sup>69</sup>, Charles Claudianos (leader)<sup>6,46</sup>, May R. Berenbaum<sup>7</sup>, Sunita Biswas<sup>6,46</sup>, Dirk C. de Graaf<sup>47</sup>, Rene Feyereisen<sup>90</sup>, Reed M. Johnson<sup>7</sup>, John G. Oakeshott<sup>46</sup>, Hilary Ranson<sup>88</sup>, Mary A. Schuler<sup>10</sup>

**DNA sequencing:** Donna Muzny (leader)<sup>1,2</sup>, Richard A. Gibbs (leader)<sup>1,2</sup>, George M. Weinstock (leader)<sup>1,2</sup>, Joseph Chacko<sup>1,2</sup>, Clay Davis<sup>1,2</sup>, Huyen Dinh<sup>1,2</sup>, Rachel Gill<sup>1,2</sup>, Judith Hernandez<sup>1,2</sup>, Sandra Hines<sup>1,2</sup>, Jennifer

Hume<sup>1,2</sup>, LaRonda Jackson<sup>1,2</sup>, Christie Kovar<sup>1,2</sup>, Lora Lewis<sup>1,2</sup>, George Miner<sup>1,2</sup>, Margaret Morgan<sup>1,2</sup>, Lynne V. Nazareth<sup>1,2</sup>, Ngoc Nguyen<sup>1,2</sup>, Geoffrey Okwuonu<sup>1,2</sup>, Heidi Paul<sup>1,2</sup>, Stephen Richards<sup>1,2</sup>, Jireh Santibanez<sup>1,2</sup>, Glenford Savery<sup>1,2</sup>, Erica Sodergren<sup>1,2</sup>, Amanda Svatek<sup>1,2</sup>, Donna Villasana<sup>1,2</sup>, Rita Wright<sup>1,2</sup>

Affiliations for participants: <sup>1</sup>Human Genome Sequencing Center, <sup>2</sup>Department of Molecular and Human Genetics, and <sup>3</sup>Department of Biochemistry, Baylor College of Medicine, One Baylor Plaza, Houston, Texas 77030, USA. <sup>4</sup>Bee Research Laboratory, BARC-E, and <sup>5</sup>National Program Staff, USDA-Agricultural Research Service, Beltsville, Maryland 20705, USA. <sup>6</sup>ARC Special Centre for the Molecular Genetics of Development, Visual Sciences, Research School of Biological Sciences, The Australian National University, Canberra, Australian Capital Territory 0200, Australia. <sup>7</sup>Department of Entomology, <sup>8</sup>Department of Computer Science, <sup>9</sup>Department of Cell and Developmental Biology, <sup>10</sup>Department of Cell and Structural Biology, <sup>11</sup>Department of Animal Biology, <sup>12</sup>Animal Sciences, <sup>13</sup>Neuroscience Program, <sup>14</sup>Program in Ecology and Evolutionary Biology, and <sup>15</sup>Department of Chemistry, University of Illinois at Urbana-Champaign, Urbana, Illinois 61801, USA. <sup>16</sup>Bee Power, L.P., 16484 CR 319, Lynn Grove Road, Navasota, Texas 77868, USA. <sup>17</sup>Heinrich-Heine Universitaet Duesseldorf, Institut fuer Genetik, Universitaetsstrasse 1, 40225 Duesseldorf, Germany. <sup>18</sup>European Molecular Biology Laboratory, Meyerhofstrasse 1, 69117 Heidelberg, Germany. <sup>19</sup>Max Delbrück Center for Molecular Medicine, Robert-Roessle-Strasse 10, 13125 Berlin-Buch, Germany. <sup>20</sup>Department of Animal Science, and <sup>21</sup>Department of Entomology, Texas A&M University, College Station, Texas 77843, USA. <sup>22</sup>Department of Chemistry, and <sup>23</sup>Department of Biology and Biochemistry, University of Houston, Houston, Texas 77204, USA. <sup>24</sup>Departamento de Genética, Faculdade de Medicina de Ribeirão Preto, <sup>25</sup>Departamento de Biologia Celular e Molecular e Bioagentes Patogênicos, Faculdade de Medicina de Ribeirão Preto, and <sup>26</sup>Departamento de Biologia, Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto 14049-900, Brazil. <sup>27</sup>Department of Entomology, Purdue University, West Lafayette, Indiana 47907, USA. <sup>28</sup>Department of Genetic Medicine and Development, University of Geneva Medical School CMU, 1 rue Michel-Servet, 1211 Geneva, Switzerland. <sup>29</sup>School of Life Sciences, Arizona State University, PO Box 874501, Tempe, Arizona 85287-4501, USA. <sup>30</sup>Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, Brazil. <sup>31</sup>Institut für Zoologie, Molekulare Ökologie, Martin-Luther-Universität Halle-Wittenberg, Hoher Weg 4, D-06099 Halle (Saale), Germany. <sup>32</sup>Department of Entomology, University of Arizona, Tucson, Arizona 85721-0036, USA. <sup>33</sup>Laboratory for Genome Exploration Research Group, RIKEN Genomic Sciences Center, Yokohama 230-0045, Japan. <sup>34</sup>Institut für Medizinische Strahlenkunde und Zellforschung, Versbacher Strasse 5, 97078 Würzburg, Germany. <sup>35</sup>Laboratory of Developmental Physiology, Genomics and Proteomics, K.U. Leuven, Naamsestraat 59 B-3000 Leuven, Belgium. <sup>36</sup>Laboratory for Evolution and Development, Biochemistry Department, and <sup>37</sup>Zoology Department, University of Otago, PO Box 56, Dunedin, New Zealand. <sup>38</sup>Department of Evolution, Systematics, and Ecology, <sup>39</sup>The Sudarsky Center for Computational Biology, and <sup>40</sup>Department of Biological Chemistry, The Alexander Silberman Institute of Life Sciences, The Hebrew University of Jerusalem, Jerusalem 91904, Israel. <sup>41</sup>Center for Functional and Comparative Insect Genomics, Department of Cell Biology and Comparative Zoology, Institute of Biology, University of Copenhagen, Universitetsparken 15, DK-2100 Copenhagen, Denmark. <sup>42</sup>Department of Biology, New York University, New York, New York 10003, USA. <sup>43</sup>Neurobiology, FB Biology/Chemistry/Pharmacy, Free University Berlin, Koenigin-Luise-Strasse 28/30, 14195 Berlin, Germany. <sup>44</sup>MRC Functional Genetics Unit, Department of Physiology Anatomy and Genetics, Le Gros Clark Building, University of Oxford, South Parks Road, Oxford OX1 3QX, UK. <sup>45</sup>The Picower Institute for Learning and Memory and the Department of Biology, Massachusetts Institute of Technology, Cambridge, Massachusetts 02139, USA. <sup>46</sup>CSIRO Entomology, GPO Box 1700, Canberra, Australian Capital Territory 2601, Australia. <sup>47</sup>Laboratory of Zoophysiology, University of Ghent, K. L. Ledeganckstraat 35, B-9000 Ghent, Belgium. <sup>48</sup>Department of Biology, Wake Forest University, Winston-Salem, North Carolina 27109, USA. <sup>49</sup>USDA-ARS-GMPRC, 1515 College Avenue, Manhattan, Kansas 66502, USA. <sup>50</sup>Division of Biology, Ackert Hall, <sup>51</sup>Department of Biochemistry, Kansas State

University, Manhattan, Kansas 66506, USA. <sup>52</sup>Department of Cellular Biology, University of Georgia, Athens, Georgia 30602, USA. <sup>53</sup>School of Life Sciences, University of Nevada Las Vegas, 4505 Maryland Parkway, Box 454004, Las Vegas, Nevada 89154-4004, USA.  
<sup>54</sup>Graduate School of Science, The University of Tokyo, Bunkyo-ku, Tokyo 113-0033, Japan.  
<sup>55</sup>Graduate School of Bioagricultural Sciences, Nagoya University, Chikusa, Nagoya 464-8601, Japan. <sup>56</sup>Laboratoire Evolution, Génomes et Spéciation Centre National de la Recherche Scientifique, 91198 Gif-sur-Yvette, France. <sup>57</sup>Fellowship for Interpretation of Genomes, 15W155 81st Street, Burr Ridge, Illinois 60527, USA. <sup>58</sup>US National Institutes of Health, National Human Genome Research Institute, 31 Center Drive, Bethesda, Maryland 20892, USA. <sup>59</sup>National Center for Biotechnology Information, National Library of Medicine, Department of Health and Human Services, 8600 Rockville Pike, Bethesda, Maryland 20894, USA. <sup>60</sup>Centre de Biologie et de Gestion des Populations, Institut National de la Recherche Agronomique, 34988 Saint-Gély-du-Fesc, France. <sup>61</sup>Institute for Cellular and Molecular Biology and Section of Integrative Biology, University of Texas, Austin, Texas 78712, USA. <sup>62</sup>Virginia Bioinformatics Institute 0477, Bioinformatics Facility, Washington Street, Virginia Tech, Blacksburg, Virginia 24061, USA. <sup>63</sup>Division of Genetics, Genomics and Development, Department of Molecular and Cell Biology, University of California, Berkeley, California 94720, USA. <sup>64</sup>Genomics Division, Lawrence Berkeley National Laboratory, Berkeley, California 94720, USA. <sup>65</sup>The Wellcome Trust Sanger Institute, Wellcome Trust Genome Campus, Hinxton, Cambridge CB10 1SA, UK. <sup>66</sup>Softberry Inc., 116 Radio Circle, Suite 400, Mount Kisco, New York 10549, USA. <sup>67</sup>Penn Genomics Institute, University of Pennsylvania, Philadelphia, Pennsylvania 19104, USA. <sup>68</sup>Royal Holloway, University of London, Egham, Surrey TW20 0EX, UK. <sup>69</sup>Honey Bee Unit, USDA-ARS, 2413 East highway 83, Number 213, Weslaco, Texas 78596, USA. <sup>70</sup>Slovak Academy of Sciences, Dubravská cesta 21, 845 51 Bratislava 45, Slovakia. <sup>71</sup>Department of Entomology, and <sup>72</sup>Department of Molecular Biology and Genetics, Cornell University, Ithaca 14853, New York, USA. <sup>73</sup>Department of Molecular and Cellular Biology, Harvard University, Cambridge, Massachusetts 02138, USA. <sup>74</sup>Institut de Biologie Moléculaire et Cellulaire, CNRS, 15 rue René Descartes, 67084 Strasbourg Cedex, France. <sup>75</sup>Umeå Centre for Molecular Pathogenesis, By. 6L, Umeå University, S-901 87 Umeå, Sweden. <sup>76</sup>Department of Entomology and Plant Pathology, Oklahoma State University, 127 NRC, Stillwater, Oklahoma 74078, USA. <sup>77</sup>National Institute of Livestock and Grassland Science, 3-1-1 Kannondai, Tsukuba, Ibaraki, 305-8517, Japan. <sup>78</sup>School of Biological Sciences, University of Sydney, New South Wales 2006, Australia. <sup>79</sup>BACPAC Resources, Children's Hospital Oakland Research Institute, Oakland, California 94609, USA. <sup>80</sup>Laboratoire de Biométrie et Biologie Evolutive, UMR 5558, CNRS, Univ. Lyon 1, 69622 Villeurbanne Cedex, France.  
<sup>81</sup>Department of Entomology, W.M. Keck Center for Behavioral Biology, Gardner Hall, MC 7613, North Carolina State University, Raleigh, North Carolina 27695, USA. <sup>82</sup>Department of Entomology, Washington State University, Pullman, Washington 99164, USA. <sup>83</sup>Department of Ecology & Evolutionary Biology/Entomology, Haworth Hall, 1200 Sunnyside Avenue, University of Kansas, Lawrence, Kansas 66045, USA. <sup>84</sup>Department of Ecology and Evolutionary Biology, University of California, Irvine, 321 Steinhaus Hall, Irvine, California 92697, USA. <sup>85</sup>NASA Ames Genome Research Facility, Moffet Field, California 94035, USA. <sup>86</sup>Systemix Institute, Cupertino, California 95014, USA. <sup>87</sup>Departement d'informatique et de recherche opérationnelle, Université de Montréal, CP 6128 succ. Centre-Ville, Montréal, Québec H3C 3J7, Canada. <sup>88</sup>Vector Research, Liverpool School of Tropical Medicine, Pembroke Place, Liverpool L3 5QA, UK. <sup>89</sup>Research Institute of Oncology, L'Hospitalet 08907, Catalonia, Spain. <sup>90</sup>Institut National de la Recherche Agronomique and Université de Nice Sophia Antipolis, UMR 1112, Centre de Recherche de Sophia Antipolis, 06903 Sophia Antipolis, France.

## 2. GenBank a UniProt – základné sekvenčné databázy



Úvodná web-stránka databázy GenBank:

<http://www.ncbi.nlm.nih.gov/genbank/>

S NCBI Resources How To Sign in to NCBI

GenBank Nucleotide Search

GenBank Submit Genomes WGS Metagenomes TPA TSA INSDC Other

### GenBank Overview

**What is GenBank?**

GenBank® is the NIH genetic sequence database, an annotated collection of all publicly available DNA sequences ([Nucleic Acids Research, 2013 Jan;41\(D1\):D36-42](#)). GenBank is part of the [International Nucleotide Sequence Database Collaboration](#), which comprises the DNA DataBank of Japan (DDBJ), the European Nucleotide Archive (ENA), and GenBank at NCBI. These three organizations exchange data on a daily basis.

A GenBank release occurs every two months and is available from the [ftp site](#). The [release notes](#) for the current version of GenBank provide detailed information about the release and notifications of upcoming changes to GenBank. Release notes for [previous GenBank releases](#) are also available. GenBank growth statistics for both the traditional GenBank divisions and the WGS division are available from each release. GenBank growth [statistics](#) for both the traditional GenBank divisions and the WGS division are available from each release.

An [annotated sample GenBank record](#) for a *Saccharomyces cerevisiae* gene demonstrates many of the features of the GenBank flat file format.

### Access to GenBank

There are several ways to search and retrieve data from GenBank.

- Search GenBank for sequence identifiers and annotations with [Entrez Nucleotide](#).
- Search and align GenBank sequences to a query sequence using [BLAST](#) (Basic Local Alignment Search Tool). BLAST searches CoreNucleotide, dbEST, and dbGSS independently; see [BLAST info](#) for more information about the numerous BLAST databases.
- Search, link, and download sequences programmatically using [NCBI e-utilities](#).
- The ASN.1 and flatfile formats are available at NCBI's anonymous FTP server: <ftp://ftp.ncbi.nlm.nih.gov/ncbi-asn1> and <ftp://ftp.ncbi.nlm.nih.gov/genbank>.

### GenBank Data Usage

The GenBank database is designed to provide and encourage access within the scientific community to the most up-to-date and comprehensive DNA sequence information. Therefore, NCBI places no restrictions on the use or distribution of the GenBank data. However, some submitters may claim patent, copyright, or other intellectual property rights in all or a portion of the data they have submitted. NCBI is not in a position to assess the validity of such claims, and therefore cannot provide comment or unrestricted permission concerning the use, copying, or distribution of the information contained in GenBank.

### Confidentiality

Some authors are concerned that the appearance of their data in GenBank prior to publication will compromise their work. GenBank will, upon request, withhold release of new submissions for a specified period of time. However, if the accession number or sequence data appears in print or online prior to the specified date, your sequence will be released. In order to prevent the delay in the appearance of published sequence data, we urge authors to inform us of the appearance of the published data. As soon as it is available, please send the full publication data—all authors, title, journal, volume, pages and date—to the following address: [update@ncbi.nlm.nih.gov](mailto:update@ncbi.nlm.nih.gov)

### Privacy

If you are submitting human sequences to GenBank, do not include any data that could reveal the personal identity of the source. GenBank assumes that the submitter has received any necessary informed consent authorizations required prior to submitting sequences.

[Disclaimer](#) [Privacy statement](#)

You are here: NCBI Support Center

**GETTING STARTED**

- NCBI Education
- NCBI Help Manual
- NCBI Handbook
- Training & Tutorials
- Submit Data

**RESOURCES**

- Chemicals & Bioassays
- Data & Software
- DNA & RNA
- Domains & Structures
- Genes & Expression
- Genetics & Medicine
- Genomes & Maps
- Homology
- Literature
- Proteins
- Sequence Analysis
- Taxonomy
- Variation

**POPULAR**

- PubMed
- Bookshelf
- PubMed Central
- BLAST
- Nucleotide
- Genome
- SNP
- Gene
- Protein
- PubChem

**FEATURED**

- Genetic Testing Registry
- GenBank
- Reference Sequences
- Gene Expression Omnibus
- Genome Data Viewer
- Human Genome
- Mouse Genome
- Influenza Virus
- Primer-BLAST
- Sequence Read Archive


**NCBI INFORMATION**

- About NCBI
- Research at NCBI
- NCBI News & Blog
- NCBI FTP Site
- NCBI on Facebook
- NCBI on Twitter
- NCBI on YouTube
- Privacy Policy

National Center for Biotechnology Information, U.S. National Library of Medicine  
8600 Rockville Pike, Bethesda MD, 20894 USA  
[Policies and Guidelines](#) | [Contact](#)

Last updated: 2020-06-11T15:50:50Z

Databáza GenBank je genetická sekvenčná databáza v rámci NIH (National Institutes of Health) na tzv. NCBI serveri (National Center for Biotechnology Information). Je to anotovaná kolekcia všetkých verejne dostupných DNA sekvencií. V aktuálnom vydaní – august 2020 – GenBank obsahuje viac ako 650 miliárd báz v ~218 miliónoch sekvenčných záznamoch (Obr. 2.1).



**Obr. 2.1.** Štatistika databázy GenBank. Na grafoch vľavo je naznačený nárast dát – báz (hore) a sekvencií (dolu) od roku 1983 priamo v databáze GenBank (modrá farba), resp. ako prírastky z projektov celogenómového sekvenovania – WGS (whole genome shotgun). V tabuľke vpravo sú údaje o počte báz a sekvencií v databáze GenBank od roku 1982 (hore) a tie isté údaje pre databázu GenBank a prírastky z projektov celogenómového sekvenovania – WGS (whole genome shotgun) – od roku 2018 doteraz (dole).

Zdroj: <https://www.ncbi.nlm.nih.gov/genbank/statistics/>

GenBank je súčasťou konzorcia INSDC (International Nucleotide Sequence Database Collaboration), t.j. medzinárodnej spolupráce nukleotidových sekvenčných databáz:

- (i) *GenBank* (v rámci NCBI – National Center for Biotechnology Information, Bethesda, MD, USA);
- (ii) *ENA* – European Nucleotide Archive – pôvodne EMBL Nucleotide Database (v rámci EBI – European Bioinformatics Institute, Hinxton, UK);
- (iii) *DDBJ* – DNA DataBank of Japan (v rámci NIG – National Institute of Genetics, Shizuoka, Japan).

Úvodná web-stránka konzorcia INSDC:

<http://www.insdc.org/>

The screenshot shows the homepage of the INSDC website. At the top, there is a banner with the INSDC logo and the text "International Nucleotide Sequence Database Collaboration". Below the banner, there is a navigation menu with links to "ABOUT INSDC", "POLICY", "ADVISORS", and "DOCUMENTS". On the left side, there are logos for DDBJ, ENA (European Nucleotide Archive), and NCBI. The main content area contains a section titled "International Nucleotide Sequence Database Collaboration" with a bulleted list of information about the collaboration. To the right of this list is a table comparing the data types handled by DDBJ, EMBL-EBI, and NCBI.

Data type	DDBJ	EMBL-EBI	NCBI
Next generation reads	<a href="#">Sequence Read Archive</a>	European Nucleotide Archive ( <a href="#">ENA</a> )	<a href="#">Sequence Read Archive</a>
Capillary reads	<a href="#">Trace Archive</a>		<a href="#">Trace Archive</a>
Annotated sequences	<a href="#">DDBJ</a>		<a href="#">GenBank</a>
Samples	<a href="#">BioSample</a>		<a href="#">BioSample</a>
Studies	<a href="#">BioProject</a>		<a href="#">BioProject</a>

Sekvencia v databáze je jednoznačne charakterizovaná tzv. prístupovým číslom (Accession No.). Prístupové čísla pre tú istú sekvenciu sú vo všetkých troch nukleotidových databázach – GenBank, ENA a DDBJ – rovnaké, pretože tieto tri databázy sú obsahovo totožné. Rozdiel je len v ich vizuálnom spracovaní a v tom, že ich spravujú rôzni kurátori v rámci rôznych inštitúcií. Dáta v týchto troch databázach sú rovnaké. V podstate je jedno, do ktorej databázy sú nové dátá vložené najskôr, keďže sa spolupráca, t.j. aj vzájomná výmena dát, uskutočňuje na dennej báze.

Úvodná web-stránka databázy ENA:

<https://www.ebi.ac.uk/ena/>

The screenshot shows the ENA homepage with a dark header containing links to EMBL-EBI, Services, Research, Training, About us, and a search bar. The main content area features a message posted on 2020-07-16, a recommendation to subscribe to the ENA-announce mailing list, and information about SARS-CoV-2 data submissions. Below this is a section titled "European Nucleotide Archive" with a brief description of what ENA provides. It includes four teal-colored buttons for "Submit", "Search", "Rulespace", and "Support". To the right, there is a "Tweets" sidebar from the @enasequence account.

Úvodná web-stránka databázy DDBJ – DNA Data Bank of Japan:

<https://www.ddbj.nig.ac.jp/>

The screenshot shows the Bioinformation and DDBJ Center website with a dark header featuring the DDBJ logo, a "Services" dropdown, and links for "Login & Submit", "Policies and Disclaimers", "Contact", and "Japanese". The main content area has a heading "Bioinformation and DDBJ Center" and a sub-section "BI-DDBJ Web Sites" with a "Google Custom Search" bar. Below this, a message states that the center provides sharing and analysis services for life science research. There are eight icons arranged in two rows: "Search & Analysis" (monitor), "Submissions" (database), "Downloads" (down arrow), "SuperComputer" (server), "Statistics" (bar chart), "Activities" (pencil), "Training" (graduation cap), and "About Us" (two people).

V nukleotidových databázach sa okrem samotnej nukleotidovej sekvencie nachádza aj jej preklad („translation“), t.j. aminokyselinová sekvencia. V dôsledku toho, že jeden najmä dlhší nukleotidový úsek môže kódovať viac proteínov, jednoznačnejším indikátorom danej sekvencie je tzv. „protein\_id“, ktoré predstavuje prístupové číslo konkrétnej aminokyselinovej sekvencie v pod-databáze GenPept v rámci celej databázy GenBank.

Záznam v databáze GenBank pre DNA kuracej triózafosfátizomerázy  
(prístupové číslo: M11941; protein\_id: AAA49095.1):

NCBI Resources How To Sign in to NCBI

Nucleotide Nucleotide Search Advanced Help

GenBank ▾ Send to: ▾ Change region shown ▾ Customize view ▾ Analyze this sequence Run BLAST

**Chicken triosephosphate isomerase (TIM) gene, complete cds**

GenBank: M11941.1

FASTA Graphics

Go to: ▾

LOCUS CHKTIMA 3900 bp DNA linear VRT 28-APR-1993

DEFINITION Chicken triosephosphate isomerase (TIM) gene, complete cds.

ACCESSION M11941

VERSION M11941.1

KEYWORDS D-glyceraldehyde 3-phosphate ketol-isomerase; triose-phosphate isomerase.

SOURCE Gallus gallus (chicken)

ORGANISM [Gallus gallus](#)  
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi; Archelosauria; Archosauria; Dinosauria; Saurischia; Theropoda; Coelurosauria; Aves; Neognathae; Galloanserae; Galliformes; Phasianidae; Phasianinae; Gallus.

REFERENCE 1 (bases 1 to 3900)

AUTHORS Straus,D. and Gilbert,W.

TITLE Genetic engineering in the Precambrian: structure of the chicken triosephosphate isomerase gene

JOURNAL Mol Cell Biol 5 (12), 3497-3506 (1985)

PUBMED [3837846](#)

COMMENT Original source text: Chicken embryonic muscle DNA.

FEATURES Location/Qualifiers

source 1..3900  
/organism="Gallus gallus"  
/mol\_type="genomic DNA"  
/db\_xref="taxon:[9031](#)"

[prim transcript](#) 273..3198  
/note="TIM mRNA and introns"  
join(324..435,1269..1392,1487..1571,1707..1839,2070..2155,  
2292..2379,2634..2752)  
/note="triosephosphate isomerase (EC 5.3.1.1)"  
/codon\_start=1  
/protein\_id="[AAA49095.1](#)"  
/translation="MAPRKFFVGGNWKMNGDKKSLGELIHTLNGAKLSADTEVVCgap  
SIYLDFAQRQLDAKIGVAACNQCYKVPKGAFTGEGISPAKIDIGAAWVILGHSERRHVF  
GESDELIGQKVVAHALAEGLGVIACTIGEKLDEREAGITEKVVFQTKAIADNVKDWSKV  
VLAYEPVWAIGTGKTATPQQAQEVHEKLRGWLKSHVSDAVAQSTRIIYGGSVTGGNCK  
ELASQHVDVGFLVGGASLKPEFVDIINAKH"

[exon](#) <324..435  
/note="triosephosphate isomerase (EC 5.3.1.1)"  
/number=1

[intron](#) 436..1268  
/note="TIM, intron A"

[exon](#) 1269..1392  
/note="triosephosphate isomerase"

[intron](#) 1393..1486  
/note="TIM, intron B"

[exon](#) 1487..1571  
/note="triosephosphate isomerase"

[intron](#) 1572..1706  
/note="TIM, intron C"

[exon](#) 1707..1839  
/note="triosephosphate isomerase"

[intron](#) 1840..2069  
/note="TIM, intron D"

[exon](#) 2070..2155  
/note="triosephosphate isomerase"



Záznam v databáze GenBank pre mRNA kuracej triózafosfátizomerázy  
 (prístupové číslo: M11314; protein\_id: AAA49094.1):

NCBI Resources How To

Nucleotide Nucleotide Advanced Search Help

GenBank ▾ Send to: ▾ Change region shown ▾  
 Chicken triosephosphate isomerase (TIM, D-glyceraldehyde 3-phosphate ketol-isomerase) mRNA, complete cds  
 GenBank: M11314.1  
[FASTA](#) [Graphics](#)

Customize view Analyze this sequence Run BLAST Pick Primers

[Go to: ▾](#)

LOCUS	CHKTIM	1303 bp	mRNA	linear	VRT 28-APR-1993
DEFINITION	Chicken triosephosphate isomerase (TIM, D-glyceraldehyde 3-phosphate ketol-isomerase) mRNA, complete cds.				
ACCESSION	M11314				
VERSION	M11314.1				
KEYWORDS	D-glyceraldehyde 3-phosphate ketol-isomerase; isomerase; triose-phosphate isomerase.				
SOURCE	Gallus gallus (chicken)				
ORGANISM	<a href="#">Gallus gallus</a>	Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi; Archelosauria; Archosauria; Dinosauria; Saurischia; Theropoda; Coelurosauria; Aves; Neognathae; Galloanserae; Galliformes; Phasianidae; Phasianinae; Gallus.			
REFERENCE	1 (bases 1 to 1303)				
AUTHORS	Straus,D. and Gilbert,W.				
TITLE	Chicken triosephosphate isomerase complements an Escherichia coli deficiency				
JOURNAL	Proc Natl Acad Sci U S A 82 (7), 2014-2018 (1985)				
PUBMED	<a href="#">3885220</a>				
COMMENT	Original source text: Chicken breast muscle cDNA to mRNA.				
FEATURES	Location/Qualifiers				
source	1..1303 /organism="Gallus gallus" /mol_type="mRNA" /db_xref="taxon: <a href="#">9031</a> "				
CDS	118..864 /note="TIM" /codon_start=1 /protein_id=" <a href="#">AAA49094.1</a> " /translation="MAPRKFFVGGNWKMNGDKKSLGELIHTLNGAKLSADTEVVCGAP SIYLDIFARQKLDAKIGVAACQNCYKVPKGAFTGEGISPAMIKDIGAAWVILGHSERRHVF GESDELIGQKVVAHALAEGLGVIACTIGEKLDEREAGITEKVVFEQTAKIAIDNVKDWSKV VIAYEPVWAIGTGTATPQQAQEVEHKLRGWLKSHVSDAVAQSTRIIYGGSVTGGNCK ELASQHDVDGFVLGGASLKPEFVDIINAKH"				
ORIGIN	1 ggggctacgg ggggtggggc ttgcgcgcc gccggcctat aaaagcgccc gccgcggc 61 cgtggccgttgc cgcacccgtc cttgcgcgc tgctgttcgc cgccgtcgc ctccgc 121 gctcccaagg agttcttcgt gggtgccaaac tggaaatgtga acggcgacaa gaagagcttgc 181 ggcgacttc tccacacgtc gaatggccccc aagcttcgtt ccgcacccga ggttgtttgc 241 ggagccccctt caatcttaccc tggatggccccc cggcagaacg ttgtgcaaaa gattggagtt 301 gcacacaaaa actgttacaa ggtaccgaag ggtgtttca caggagat cagccac 361 atgtcaaaat atattggagc tgcattgggtt atcctggcc actcagacgq gaggcatgtt 421 tttggagagt ctgtatgtt gattggccag aagggtgttgc atgtcttgc tgaaggc 481 ggtgtcatcg cttgcattgg ggagaagctg gatgagagag aagctggcat aacggagaag 541 gtgtgtttt aacagaccaa agctattgtc gataactgtc aggactggag taagggtgtt 601 cttgcctatg agccatgtt ggttatcgaa actgttaaaa ctgtactcc ccaacaggct 661 caggaggatc atgagaagctt gagaggctgg ctcaaaagcc acgtgtctga tgctgtgt 721 cagtcacta ggatcatcta tggagggttca gtcactgtt gcaactgtaa ggaactggcc 781 tcccaagcatg atgtggatgg cttccttgc ggtggggctt ctctcaagcc agatgttgc 841 gatattatca atgcaaaaaca ttaaaggcgc ctgtggggag cagttccat cggtaagag 901 caagaaaactg aagcaagaag ggacccgtt tgcacgtt ctcggatcag aggcttctt 961 tgaggcttc cccaccacc acaattatttgc ttcttagtgc gctgtcaacc cccaccac 1021 tggtggatc ccattatgtt gagccatct cagcagatc tccttcttgc actggcaaaa 1081 tccttgcgttca tctgttgc tggtagagcc cacatgtcaac ctggccatttgc cttctcttc 1141 tttcagcccc tgcaggaggagg gggggccact agtactgggg ggaagaaaaa ggaaccacca 1201 tcttcgttcat cttcagatc catccgcac gggctggca gcttagaccc ttgtgagaca 1261 ctttacatca ccaatgttgc ttattgttca ataaatgttca agg				

Záznam v databáze GenBank/GenPept pre aminokyselinovú sekvenciu kuracej triózafosfátizomerázy (prístupové číslo: AAA49095.1) – preklad z DNA (prístupové číslo: M11941):

NCBI Resources How To

Protein Protein Search Advanced Help

GenPept Send to: Change region shown

**triosephosphate isomerase (EC 5.3.1.1) [Gallus gallus]**

GenBank: AAA49095.1

Identical Proteins FASTA Graphics

Go to: ▾ Analyze this sequence Run BLAST

```

LOCUS      AAA49095          248 aa      linear VRT 28-APR-1993
DEFINITION triosephosphate isomerase (EC 5.3.1.1) [Gallus gallus].
ACCESSION  AAA49095
VERSION    AAA49095.1
DBSOURCE   locus CHKTIMA accession M11941.1
KEYWORDS   .
SOURCE     Gallus gallus (chicken)
ORGANISM   Gallus gallus
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
Archeosauria; Archosauria; Dinosauria; Saurischia; Theropoda;
Coelurosauria; Aves; Neognathae; Galloanserae; Galliformes;
Phasianidae; Phasianinae; Gallus.
REFERENCE  1 (residues 1 to 248)
AUTHORS   Straus,D. and Gilbert,W.
TITLE     Genetic engineering in the Precambrian: structure of the chicken
          triosephosphate isomerase gene
JOURNAL   Mol Cell Biol 5 (12), 3497-3506 (1985)
PUBMED    3837846
COMMENT    Method: conceptual translation.
FEATURES
  source
    1..248
    /organism="Gallus gallus"
    /db_xref="taxon:9031"
  Protein
    1..248
    /name="triosephosphate isomerase (EC 5.3.1.1)"
  Region
    1..246
    /region_name="PTZ00333"
    /note="triosephosphate isomerase; Provisional"
    /db_xref="CDD:240365"
  Site
    order(11,13,95,165,171,211,230,232..233)
    /site_type="other"
    /note="substrate binding site [chemical binding]"
    /db_xref="CDD:238190"
  Site
    order(11,14,45..47,49,52,64,82,85..86,97..98)
    /site_type="other"
    /note="dimer interface [polypeptide binding]"
    /db_xref="CDD:238190"
  Site
    order(13,95,165)
    /site_type="active"
    /note="catalytic triad [active]"
    /db_xref="CDD:238190"
  CDS
    1..248
    /coded_by="join(M11941.1:324..435,M11941.1:1269..1392,
                  M11941.1:1487..1571,M11941.1:1707..1839,
                  M11941.1:2070..2155,M11941.1:2292..2379,
                  M11941.1:2634..2752)"
ORIGIN
  1 maprkffvvg nwkmngdkks lgelihtlng aklsadtevv cgapsiyldf arqkldakig
  61 vaaqncvkyvp kgaftgeisp amikdigaaaw vilghserrh vfgesdelig qkvahalaeg
  121 lgviacigek ldereagite kvvfeqtkai adnvkdwskv vlayepvwai gtgktatpqq
  181 aqevheklrg wlkshvsdav aqstriiygg svtggnckel asqhdvdgfl vggaslkpief
  241 vdiinakh

```

Záznam v databáze GenBank/GenPept pre aminokyselinovú sekvenciu kuracej triózafosfátizomerázy (prístupové číslo: AAA49094.1) – preklad z mRNA (prístupové číslo: M11314):

NCBI Resources How To

Protein Protein Search Advanced Help

GenPept Send to: Change region shown

**TIM [Gallus gallus]**

GenBank: AAA49094.1

Identical Proteins FASTA Graphics

Go to: ▾ Customize view Analyze this sequence Run BLAST

LOCUS AAA49094 248 aa linear VRT 28-APR-1993

DEFINITION TIM [Gallus gallus].

ACCESSION AAA49094

VERSION AAA49094.1

DBSOURCE locus CHKTIM accession [M11314.1](#)

KEYWORDS .

SOURCE Gallus gallus (chicken)

ORGANISM [Gallus gallus](#) Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi; Archelosauria; Archosauria; Dinosauria; Saurischia; Theropoda; Coelurosauria; Aves; Neognathae; Galloanserae; Galliformes; Phasianidae; Phasianinae; Gallus.

REFERENCE 1 (residues 1 to 248)

AUTHORS Straus,D. and Gilbert,W.

TITLE Chicken triosephosphate isomerase complements an Escherichia coli deficiency

JOURNAL Proc Natl Acad Sci U S A 82 (7), 2014-2018 (1985)

PUBMED [3885220](#)

COMMENT Method: conceptual translation.

FEATURES Location/Qualifiers

source 1..248 /organism="Gallus gallus" /db\_xref="taxon:[9031](#)"

Protein 1..248 /name="TIM"

Region 1..246 /region\_name="PTZ00333" /note="triosephosphate isomerase; Provisional" /db\_xref="CDD:[240365](#)"

Site order(11,13,95,165,171,211,230,232..233) /site\_type="other" /note="substrate binding site [chemical binding]" /db\_xref="CDD:[238190](#)"

Site order(11,14,45..47,49,52,64,82,85..86,97..98) /site\_type="other" /note="dimer interface [polypeptide binding]" /db\_xref="CDD:[238190](#)"

Site order(13,95,165) /site\_type="active" /note="catalytic triad [active]" /db\_xref="CDD:[238190](#)"


CDS 1..248 /coded\_by="M11314.1:118..864"

ORIGIN

```

1 maprkffvvg nwkmngdkks lgelihtlng aklsadtevv cgapsiyldf arqkldakig
61 vaaqncykvp kgaftgeisp amikdigaaw vilghserrh vfgesdelig qkvalahalaeg
121 lgviacigek ldereagite kvvfeqtakai adnvkdwskv vlayepvwai gtgktatpqq
181 aqevheklrg wlkshvsdav agstrialygg svtggnckel asqhdvdgfl vggaslkpef
241 vdiinakh

```



Úvodná web-stránka databázy UniProt:

<http://www.uniprot.org/>

The mission of UniProt is to provide the scientific community with a comprehensive, high-quality and freely accessible resource of protein sequence and functional information.

**UniProtKB**  
UniProt Knowledgebase

**Swiss-Prot (563,552)**  
Manually annotated and reviewed.  
Records with information extracted from literature and curator-evaluated computational analysis.

**TrEMBL (195,104,019)**  
Automatically annotated and not reviewed.  
Records that await full manual annotation.

**UniRef**

Sequence clusters

**UniParc**

Sequence archive

**Proteomes**

Proteome sets

**Supporting data**

<p>Literature citations</p>	<p>Taxonomy</p>	<p>Subcellular locations</p>
Cross-ref. databases	Diseases	Keywords

**News**

Forthcoming changes  
There are currently no changes planned

UniProt release 2020\_05  
PCK1 vacillating between gluconeogenesis and lipogenesis | Cross-references to CPTC, BMRB, PCDDB and SASBDB

UniProt release 2020\_04  
Inflammation: the Good, the Bad and the Ugly | Cross-references to GlyGen and PathwayCommons | New automatic annotation system ARBA (Asso...)

News archive

**Getting started**

- [Text search](#)  
Our basic text search allows you to search all the resources available
- [BLAST](#)  
Find regions of similarity between your sequences
- [Sequence alignments](#)  
Align two or more protein sequences using the Clustal Omega program
- [Retrieve/ID mapping](#)  
Batch search with UniProt IDs or convert them to another type of database ID (or vice versa)
- [Peptide search](#)  
Find sequences that exactly match a query peptide sequence

**UniProt data**

- [Download latest release](#)  
Get the UniProt data
- [Statistics](#)  
View Swiss-Prot and TrEMBL statistics
- [How to cite us](#)  
The UniProt Consortium
- [Submit your data](#)  
Submit your sequences, publications and annotation updates
- [Programmatic access](#)  
Query UniProt data using APIs providing REST, SPARQL and Java services

**Protein spotlight**

A Wasp's Sting  
October 2020

Nature has always inspired humans. We extract scents from flowers to make perfume, and use pigments from minerals to reproduce colours. We copy the streamlined bodies of birds to build planes, and mimic the toughness of spider silk to design textiles. As our knowledge accumulates, and technology evolves, we have even reached a point where we are able to tamper with the very basics of Nature to twist it to our advantage...

**Tools**

- [BLAST](#)
- [Align](#)
- [Retrieve/ID mapping](#)
- [Peptide search](#)

**Core data**

- Protein knowledgebase (UniProtKB)
- Sequence clusters (UniRef)
- Sequence archive (UniParc)
- Proteomes

**Supporting data**

- Literature citations
- Taxonomy
- Keywords
- Subcellular locations
- Cross-referenced databases
- Diseases

**Information**

- About UniProt
- Help
- FAQ
- UniProtKB manual
- Technical corner
- Expert biocuration

© 2002 – 2020 UniProt Consortium | License & Disclaimer | Privacy Notice

UniProt is an ELIXIR core data resource

Main funding by:

State Secretariat for Education, Research and Innovation SERI

Databáza UniProt KnowledgeBase (UniProt KB) je centrom pre kolekciu informácií o proteínoch so správnou, konzistentnou a bohatou anotáciou o ich funkciách. Je spravovaná v rámci EBI (European Bioinformatics Institute), ktorý predstavuje „vlajkovú loď“ v oblasti bioinformatiky v Európe.

UniProtKB pozostáva z dvoch základných súčasťí:

- (i) SwissProt – manuálne anotované záznamy (recenzované záznamy);
- (ii) TrEMBL – automaticky anotované, t.j. počítačovo analyzované záznamy (nerecenzované záznamy, očakávajúce plnú anotáciu).

Databáza UniProt pôvodne bola založená a existovala ako databáza SwissProt a bola spravovaná v rámci Swiss Institue of Bioinformatics na tvz. Expasy serveri (<http://www.expasy.ch/>, resp. <http://www.expasy.org/>).

Kedže dominanciu získali databázy s nukleotidovými sekvenciami (GenBank, EMBL/ENA, DDBJ) – v dôsledku prevahy sekvenovania nukleotidov pred sekvenovaním aminokyselín – k databáze SwissProt bola vytvorená jej súčasť TrEMBL, t.j. preložená EMBL nukleotidová databáza (translated EMBL Nucleotide Database – TrEMBL). V súčasnosti pribúdajú dátá do databázy UniProt takmer výhradne cez jej súčasť TrEMBL, keďže aminokyselinové sekvencie sa nezískavajú priamo sekvenovaním proteínov, ale prekladom nukleotidových sekvencií. Treba si ale uvedomiť, že EMBL Nucleotide Database je v súčasnosti databáza ENA (European Nucleotide Archive).

Prístupové číslo sekvencie proteínu v databáze UniProt je odlišné od prístupového čísla pre tú istú sekvenciu proteínu a jeho génu z databázy GenBank (ENA a DDBJ). Prístupové čísla z nukleotidových databáz, ako aj číslo „protein\_id“ z GenPept, sú však súčasťou každého záznamu v databáze UniProt v časti „Cross-references“.

## UniProt záznam pre triózafosfátizomerázu (prístupové číslo P00940):

**UniProtKB - P00940 (TPIS\_CHICK)**

**Display**    **BLAST**    **Align**    **Form**    **Add to basket**    **History**    **Help video**    **Add a publication**    **Feedback**

**Protein** Triosephosphate isomerase  
**Gene** TP11  
**Organism** Gallus gallus (Chicken)  
**Status** Reviewed - Annotation score: 5 - Experimental evidence at protein level!

**Function:**

Triosephosphate isomerase is an extremely efficient metabolic enzyme that catalyzes the interconversion between dihydroxyacetone phosphate (DHAP) and D-glyceraldehyde-3-phosphate (G3P) in glycolysis and gluconeogenesis. [By similarity](#)

It is also responsible for the non-negligible production of methylglyoxal a reactive cytotoxic side-product that modifies and can alter proteins, DNA and lipids. [By similarity](#)

**Catalytic activity:**

- dihydroxyacetone phosphate = methylglyoxal + phosphate [By similarity](#)

EC:4.2.3.3 [By similarity](#)

Source: Rhea, [Rhe](#)

**Chemical reaction:**

$$\text{dihydroxyacetone phosphate} \rightleftharpoons \text{methylglyoxal} + \text{phosphate}$$

**Pathway:** glycolysis

This protein is involved in step 1 of the subpathway that synthesizes D-glyceraldehyde 3-phosphate from glyceral phosphate. [PROSITE-ProRule annotation](#)

EC:5.3.1.1 [PROSITE-ProRule annotation](#)

Source: Rhea, [Show](#)

**Pathway:** glycolysis

This protein is involved in step 1 of the subpathway that synthesizes D-glyceraldehyde 3-phosphate from glyceral phosphate, the pathway glycolysis and in Carbohydrate degradation.

**Pathway:** gluconeogenesis

This protein is involved in the pathway gluconeogenesis, which is part of Carbohydrate biosynthesis. [PROSITE-ProRule annotation](#)

View all proteins of this organism that are known to be involved in the subpathway that synthesizes D-glyceraldehyde 3-phosphate from glyceral phosphate, the pathway glycolysis and in Carbohydrate degradation.

**Sites**

Feature key	Position(s)	Description	Actions	Graphical view	Length
Binding site <sup>1</sup>	11	Substrate <a href="#">Combined sources</a> <a href="#">1 Publication</a>			1
Binding site <sup>1</sup>	13	Substrate <a href="#">Combined sources</a> <a href="#">1 Publication</a>			1
Active site <sup>1</sup>	95	Electrophile <a href="#">Combined sources</a> <a href="#">1 Publication</a>			1
Active site <sup>1</sup>	165	Proton acceptor <a href="#">Combined sources</a> <a href="#">1 Publication</a>			1

**GO - Molecular function:**

- methylglyoxal synthase activity [Source: UniProtKB](#)
- protein homodimerization activity [Source: UniProtKB](#)
- triose-phosphate isomerase activity [Source: UniProtKB](#)
- ubiquitin protein ligase binding [Source: Ensembl](#)

Complete GO annotation on QuickGO ...

**GO - Biological process:**

- gluconeogenesis [Source: GO\\_Central](#)
- glyceraldehyde-3-phosphate biosynthetic process [Source: UniProtKB](#)
- glycerol catabolic process [Source: GO\\_Central](#)
- glycolytic process [Source: GO\\_Central](#)
- methylglyoxal biosynthetic process [Source: UniProtKB](#)

Complete GO annotation on QuickGO ...

**Keywords:**

Molecular function Isomerase, Lyase

Biological process Gluconeogenesis, Glycolysis

**Enzyme and pathway databases**

BRENDA<sup>1</sup> 5.3.1.1, 1306  
 Reactome<sup>1</sup> R-GGA-352875, Gluconeogenesis  
                   R-GGA-352882, Glycolysis  
                   R-GGA-70171, Glycolysis

SABIO-RK<sup>1</sup> P00940  
 UniPathway<sup>1</sup> UPA00109; UIER00189  
 UPA00138

**Names & Taxonomy:**

Protein names<sup>1</sup> Recommended name:  
**Triosephosphate isomerase** (EC:5.3.1.1 [PROSITE-ProRule annotation](#))

Alternative name(s):  
 • Short name: TIM

Gene names<sup>1</sup> Name: **TP11**  
 Organism: Gallus gallus (Chicken)  
 Taxonomic identifier: 9031 [NCBI]

Taxonomic lineage<sup>1</sup> Eukaryota > Metazoa > Chordata > Craniata > Vertebrata > Euteleostomi > Archelosauria > Archosauria > Dinosauria > Saurischia > Theropoda > Coelurosauria > Aves > Neognathae > Galloanserae > Galliformes

Proteomes<sup>1</sup> UP000000539 Component: Chromosome 1

**Subcellular location:**

UniProt annotation GO - Cellular component

Other locations

Cytoplasm [1](#) [PROSITE-ProRule annotation](#)

**Keywords - Cellular component:**

Graphics by Christian Stoll & Sean O'Donoghue, Source: COMPARTMENTS

Manual annotation Automatic computational assertion

## Záznam z databázy UniProt pre triózafosfátizomerázu (pokračovanie):

**Display**

**Cytoplasm**

**Pathology & Biotech:**

- Publications**
- Feature viewer**
- Feature table**

**PTM / Processing:**

- Mutagenesis**
- Initiator methionine<sup>1</sup>**
- Protein modifications**
- Proteomic databases**
- Expression<sup>1</sup>**
- Gene expression databases**
- Similar proteins**
- Cross references**
- Entry information**
- Miscellaneous**

**Top**

**GO - Molecular function:**

- protein homodimerization activity (Source: UniProtKB)
- ubiquitin protein ligase binding (Source: Ensembl)

Complete GO annotation on QuickGO ...

**Protein-protein interaction databases:**

- BioGRID: 676684, 1 interactor
- IntAct: P00940, 1 interactor
- STRING: 9031.ENSGALP00000023396

**Structure:**

**Secondary structure:**

Legend: Helix (blue), Turn (pink), Beta strand (green), PDB Structure known for this area (grey).

**3D structure databases:**

- BMRB: P00940
- SMR: P00940
- ModBase: Search...
- PDBe-KB: Search...

**Miscellaneous databases:**

- EvolutionaryTrace: P00940

**Family & Domains:**

Sequence similarities<sup>1</sup>: Belongs to the triosephosphate isomerase family. (Curated)

**Phylogenomic databases:**

- eggNOG: KOG1643, Eukaryota
- GeneTree: ENSTGT0000000013754
- HOGENOM: CLU\_024251\_2\_0\_1
- InParanoid: P00940
- KO: K01803
- OMA: QEVCGAI
- OrthoDB: 127257at2759
- PhylomeDB: P00940
- TreeFam: TF300829

**Family and domain databases:**

- CD0: c00311, TIM, 1 hit
- Gene3D: 3.20.20.70, 1 hit
- HAMAP: MF\_00147\_B, TIM\_B, 1 hit
- InterPro: View protein in InterPro
  - IPR01785, Aldolase\_TIM
  - IPR01786, TIM
  - IPR022396, TrioseP\_isomerase\_bac/euk
  - IPR000652, Triosephosphate\_isomerase
  - IPR020061, Triosephosphate\_isomerase\_AS
- PANTHER: PTH221139, PTH221139, 1 hit
- Pfam: View protein in Pfam
  - PF00121, TIM, 1 hit
- SUPERFAMILY: SSF51351, SSF51351, 1 hit
- TIGRFAMs: TIGR00419, tim, 1 hit
- PROSITE: View protein in PROSITE
  - PS00171, TIM\_1, 1 hit
  - PS01440, TIM\_2, 1 hit

1SPQ	X-ray	2.16 Å	A/B	2-248	PDBe RCSB PDB PDB PDBsum
1SQ7	X-ray	2.85 Å	A/B	2-248	PDBe RCSB PDB PDB PDBsum
1SSD	X-ray	2.90 Å	A/B	2-248	PDBe RCSB PDB PDB PDBsum
1SSG	X-ray	2.90 Å	A/B	2-248	PDBe RCSB PDB PDB PDBsum
1SUS	X-ray	2.70 Å	A/B	2-248	PDBe RCSB PDB PDB PDBsum
1SW0	X-ray	1.71 Å	A/B	1-248	PDBe

## Záznam z databázy UniProt pre triózafosfátizomerázu (pokračovanie):

**Display**

**Sequence**

Entry: P00940-1 [UniParc] FASTA Add to basket + Hide

Sequence status: Complete.  
Sequence processing: The displayed sequence is further processed into a mature form.

Length: 248  
Mass (Da): 26,630  
Last modified: January 23, 2007 - v2  
Checksum: AFCC25BE574DE982

BLAST GO

Function: Name & taxonomy, Subcellular location, Pathway & Biofunc, PTM / Processing, Aglycone, Inhibitor, Structure, Family & Domains, Sequence, Similar proteins, Cross references, Entry information, Miscellaneous.

Experimental info:

Feature key	Position(s)	Description	Actions	Graphical view	Length
Sequence conflict <sup>1</sup>	17 - 18	DK → KR AA sequence (PubMed:4463937).  Curated			2
Sequence conflict <sup>1</sup>	29	N → D AA sequence (PubMed:4463937).  Curated			1
Sequence conflict <sup>1</sup>	145 - 146	EQ → QE AA sequence (PubMed:4463937).  Curated			2
Sequence conflict <sup>1</sup>	194	S → T AA sequence (PubMed:4463937).  Curated			1
Sequence conflict <sup>1</sup>	202 - 204	QST → QVS AA sequence (PubMed:4463937).  Curated			3

Sequence databases:

- Select the link M11314 mRNA Translation: AAA49094.1 destinations: M11941 Genomic DNA Translation: AAA49095.1
- EMBL<sup>1</sup>
- OpenBank<sup>1</sup>
- OboDB<sup>1</sup>
- PIR<sup>1</sup> A23448, ISCHT
- RefSeq<sup>1</sup> NP\_990782.1, NM\_205451.1

Genome annotation databases:

- Ensembl<sup>1</sup> ENSGAL00000023442; ENSGAL00000023396; ENSGAL00000014526
- ENSGAL000000071768; ENSGAL00000044536; ENSGAL00000014526
- GeneID<sup>1</sup> 396435
- KEGG<sup>1</sup> gga:396435

Similar proteins:

100% identity	90% identity	50% identity	
Protein	Similar proteins		
P00940	Triosephosphate isomerase (Fragment)	MELGA  85	UniRef100_P00940
	Triosephosphate isomerase (Fragment)	EURHL  211	
+ 1			

Full view

Cross-references:

Sequence databases:

- Select the link M11314 mRNA Translation: AAA49094.1 destinations: M11941 Genomic DNA Translation: AAA49095.1
- EMBL<sup>1</sup>
- OpenBank<sup>1</sup>
- OboDB<sup>1</sup>
- PIR<sup>1</sup> A23448, ISCHT
- RefSeq<sup>1</sup> NP\_990782.1, NM\_205451.1

3D structure databases:

PDB entry	Method	Resolution (Å)	Chain	Positions	PDBsum	
1SPQ	X-ray	2.16	A/B	2-248	[•]	
1SQ7	X-ray	2.85	A/B	2-248	[•]	
1PSD	X-ray	2.90	A/B	2-248	[•]	
1SGG	X-ray	2.90	A/B	2-248	[•]	
1SUS	X-ray	2.70	A/B	2-248	[•]	
1SWO	X-ray	1.71	A/B	1-248	[•]	
1W3	X-ray	2.03	A/B	1-248	[•]	
1W7	X-ray	2.22	A/B	1-248	[•]	
1TIM	X-ray	2.50	A/B	2-248	[•]	
1TPB	X-ray	1.90		1/2	2-248	[•]
1TCP	X-ray	1.90		1/2	2-248	[•]
1THH	X-ray	1.80		1/2	2-248	[•]
1TPU	X-ray	1.90	A/B	2-248	[•]	
1TPV	X-ray	1.90	A/B	2-248	[•]	
1TPW	X-ray	1.90	A/B	2-248	[•]	
4P61	X-ray	1.34	A/B	1-248	[•]	
8TIM	X-ray	2.50	A/B	2-248	[•]	

BMRB<sup>1</sup> P00940  
SMR<sup>1</sup> P00940  
ModBase<sup>1</sup> Search...  
PDBeXt<sup>1</sup> Search...

Protein-protein interaction databases:

- BioGRID<sup>1</sup> 676684, 1 interactor
- IntAct<sup>1</sup> P00940, 1 interactor
- STRING<sup>1</sup> 9031\_ENSGAL00000023396

Proteomic databases:

- PsDB<sup>1</sup> P00940
- PRIDE<sup>1</sup> P00940

Genome annotation databases:

- Ensembl<sup>1</sup> ENSGAL00000023442; ENSGAL00000023396; ENSGAL00000014526
- ENSGAL000000071768; ENSGAL00000044536; ENSGAL00000014526
- GeneID<sup>1</sup> 396435
- KEGG<sup>1</sup> gga:396435

Organism-specific databases:

- CTD<sup>1</sup> 7167

Phylogenetic databases:

- eggNOG<sup>1</sup> KOG1643, Eukaryota
- GeneTree<sup>1</sup> ENSGT00390000013354
- HOGENOM<sup>1</sup> CLU\_024251\_2\_0\_1
- InParanoid<sup>1</sup> P00940
- KO<sup>1</sup> K01803
- OMA<sup>1</sup> QEVCGAI
- OrthoDB<sup>1</sup> 127257at2759
- PhyloMeDB<sup>1</sup> P00940
- TreeFam<sup>1</sup> TF300829

## Záznam z databázy UniProt pre triózafosfátizomerázu (dokončenie):

**Display**

**Entry**

**Publications**

**Feature viewer**

**Feature table**

**None**

**Function**

**Name & Taxonomy**

**Subcellular location**

**Pathway & BioCart**

**PTM / Processing**

**Expression**

**Inhibition**

**Prediction**

**Family & Domains**

**Sequence**

**Similar proteins**

**Cross references**

**Entry information**

**Miscellaneous**

**Enzyme and pathway databases**

UniPathway: UP000109; UER00189  
UPA00139

BRENDA<sup>1</sup>: 5.3.1.1\_1306

Reactome<sup>2</sup>: R-GGA-352875, Gluconeogenesis  
R-GGA-352882, Glycolysis  
R-GGA-70171, Glycolysis  
R-GGA-70263, Gluconeogenesis

SABIO-RK<sup>3</sup>: P00940

**Miscellaneous databases**

EvolutionaryTrace<sup>4</sup>: P00940  
PRO<sup>5</sup>: PR:P00940

**Gene expression databases**

Bgee<sup>6</sup>: ENSGALGO00000014526, Expressed in skeletal muscle tissue and 14 other tissues

**Family and domain databases**

CD0<sup>7</sup>: cd00311, TIM, 1 hit  
Gen3D<sup>8</sup>: 3.20.20.70, 1 hit

HAMAP<sup>9</sup>: MF\_00147\_B, TIM\_B, 1 hit

InterPro<sup>10</sup>: View protein in InterPro  
IPR013785, Aldolase, TIM  
IPR035990, TIM\_sf  
IPR022396, Triosephosphate\_isomerase\_bac/euk  
IPR000001, Triosephosphate\_isomerase  
IPR020061, Triosephosphate\_isomerase\_AS

PANTHER<sup>11</sup>: PTIHC21139, PTIHC21139, 1 hit

PIR<sup>12</sup>: Virus protein in PIR  
PF00121, TIM, 1 hit

SUPERFAMILY<sup>13</sup>: SSF51351, SSFS1351, 1 hit

TIGRFAM<sup>14</sup>: TIGR00019, tim, 1 hit

PROSITE<sup>15</sup>: View protein in PROSITE  
PS00171, TIM\_1, 1 hit  
PS51440, TIM\_2, 1 hit

ProtoNet<sup>16</sup>: Search...  
MobiDB<sup>17</sup>: Search...

**Entry information:**

Entry name<sup>18</sup>: TPIS\_CHICK  
Accession<sup>19</sup>: Primary (citable) accession number: **P00940**  
Entry history<sup>20</sup>: Integrated into UniProtKB/Swiss-Prot: July 21, 1986  
Prot:  
Last sequence update: January 23, 2007  
Last modified: October 7, 2020  
This is version 162 of the entry and version 2 of the sequence. See complete history.  
Reviewed (UniProtKB/Swiss-Prot)  
Chordata Protein Annotation Program

**Miscellaneous:**

Keywords - Technical term<sup>21</sup>: 3D-structure, Direct protein sequencing, Reference proteome

Documents

- PATHWAY comments**  
Index of metabolic and biosynthesis pathways
- PDB cross-references**  
Index of Protein Data Bank (PDB) cross-references
- SIMILARITY comments**  
Index of protein domains and families

**Tools**

BLAST  
Align  
Retrieve/ID mapping  
Peptide search

**Core data**

Protein knowledgebase (UniProtKB)  
Sequence clusters (Uniref)  
Sequence archive (UniParc)  
Proteomes

**Supporting data**

Literature citations  
Taxonomy  
Keywords  
Subcellular locations  
Cross-referenced databases  
Diseases

**Information**

About UniProt  
Help  
FAQ  
UniProtKB manual  
Technical corner  
Expert biocuration

**UniProt**  
© 2002 – 2020 UniProt Consortium | License & Disclaimer | Privacy Notice  
EMBL-EBI  PIR  SIB 

UniProt is an ELIXIR core data resource

Main funding by: National Institutes of Health  EMBL-EBI  State Secretariat for Education, Research and Innovation SERI 

Pre prácu so sekvenciami – aj nukleotidovými, aj aminokyselinovými – sa používa ich zápis v tzv. FASTA formáte v textovom súbore. V ňom je každá sekvencia uvedená v prvom riadku znakom „>“, za ktorým je jej názov (napr. vhodná skratka), pričom samotná sekvencia začína na nasledujúcom riadku:

```
>sp|P00940|TPIS_CHICK Triosephosphate isomerase OS=Gallus gallus OX=9031 GN=TPI1 PE=1 SV=2
```

```
MAPRKFFVGGNWKMNGDKSLGELIHTLNGAKLSADTEVVCAGPSIYLDFAHQKLDKIG
VAAQNCYKVPKGAFGEISPAMIKDIGHAAWVLGHHSERRHVFGESDELIGQKVAHALAEG
LGVIACIGEKLDEREAGITEKVVFEQTAKIAADNVKDWSKVVLAYEPVWAIGTGTATPQQ
AQEVHEKLRWLKSHVSDAVAQSTRIIYGGSVTGGNCKELASQHDVDGFLVGGASLKPEF
VDIINAKH
```

### 3. Základy bioinformatickej – *in silico* – analýzy proteínov

Základy práce pri bioinformatickej analýze sekvencií proteínov, tzv. *in silico* analýze, možno ilustrovať na nasledujúcom vzorovom príklade. Ide o porovnanie 7 sekvencií enzymu triózafosfátizomeráza, pochádzajúcich z rôznych zástupcov baktérií, archeónov a eukaryotov (tab. 3.1).

**Tabuľka 3.1.** Zoznam študovaných triózafosfátizomeráz.

Č.	Zdroj	Skratka	UniProt	Dĺžka
	Bacteria			
1	<i>Escherichia coli</i>	Escco	P0A858	255
2	<i>Nostoc</i> sp. PCC 7120	Nossp	Q8YP17	241
	Archaea			
3	<i>Pyrococcus furiosus</i>	Pyrfu	P62002	228
4	<i>Sulfolobus solfataricus</i>	Sulso	Q97VM8	227
	Eucarya			
5	<i>Saccharomyces cerevisiae</i>	Sacce	P00942	248
6	<i>Arabidopsis thaliana</i>	Arath	Q9SKP6	255 (61-315)
7	<i>Homo sapiens</i> (izoforma 1)	Homsa	P60174	249

Celý postup práce možno zosumarizovať ako zadanie v nasledujúcich krokoch:

- (1) Vytvorte si priečinok „TIM“.
- (2) Všetkých 7 sekvencií TIM zhromaždite z databázy UniProt do vstupného súboru („TIM.txt“) vhodného pre program Clustal-Omega.
- (3) Na EBI serveri zrovnajte sekvencie TIM v programe Clustal-Omega:  
<http://www.ebi.ac.uk/Tools/msa/clustalo/>  
a získajte dva súbory: (i) formát ALIGNMENT – „Clustal with character counts“ (súbor: „TIM\_aln.txt“); a (ii) formát Pearson/FASTA (súbor: „TIM\_fas.txt“); ); dodržte vstupné poradie sekvencií (input order).
- (4) Súbor „TIM\_aln.txt“ otvorte v editovacom programe (napr. MS-Word) a v zrovnaných sekvenciách zvýraznite žltým podfarbením aminokyselinové zvyšky aktívneho miesta (Asn10, Lys12, His95 a Glu165 v sekvencii triózafosfátizomerázy zo *Saccharomyces cerevisiae*); súbor uložte ako dokument TIM\_aln.doc.

(5) Na EBI serveri v rámci nástroja Simple Phylogeny:

[http://www.ebi.ac.uk/Tools/phylogeny/simple\\_phylogeny/](http://www.ebi.ac.uk/Tools/phylogeny/simple_phylogeny/)

vypočítajte súbory pre dva evolučné stromy pre TIM: (i) s uvažovaním medzier v sekvenciach – podmienka „Exclude gaps“ je vypnutá: „off“ (súbor „TIM\_off.txt“); (ii) a s ich ignorovaním – podmienka „Exclude gaps“ je zapnutá: „on“ (súbor „TIM\_on.txt“). Oba súbory počítajte na základe finálneho súboru zrovnania sekvencií vo formáte Pearson/FASTA – „TIM\_fas.txt“ (ktorý je obsahovo zhodný so súborom zrovnania vo formáte „Clustal with character counts“ – „TIM\_aln.txt“).

(6) Vypočítajte hodnoty konsenzuálnej dĺžky (CL), sekvenčnej identity (SI) a sekvenčnej podobnosti (SS).

(7) Vypočítané evolučné stromy zobrazte v programe iTOL (Interactive Tree of Life; <https://itol.embl.de/>) – napr. v režime „display mode“ ako „circular“ (t.j. kruhový typ stromu), vložte ako exportované obrázky (napr. PNG) do súboru „TIM\_aln.doc“, porovnajte a zapíšte diskusiu celej práce.

#### *Príprava vstupného súboru*

Po vytvorení priečinku („TIM“), do ktorého sa budú – kvôli prehľadnosti – ukladať všetky údaje, je potrebné vytvoriť si tzv. vstupný súbor so sekvenciami. Tento súbor („TIM.txt“) je súbor textového typu, pričom všetky sekvencie v ňom uložené musia byť v tzv. FASTA formáte (obr. 3.1). Pre jednoduché získanie sekvencií sú v tomto konkrétnom prípade udané prístupové čísla (Accession Nos.) z databázy UniProt pre všetkých 7 študovaných triózafosfátizomeráz (tab. 3.1). Sekvencie by samozrejme mohli byť získané aj z nukleotidovej databázy (GenBank/ENA/DDBJ), ak by boli zadané prístupové čísla z týchto nukleotidových databáz, prípadne tzv. GenPept „protein\_id“ čísla (pre súbory obsahujúce iba aminokyselinové sekvencie). V každom prípade – akýmkoľvek spôsobom sa sekvencie získajú – vo vstupnom súbore sa musia uložiť vo FASTA formáte a súbor musí byť textový súbor, t.j. obsahuje iba text (nemôže to byť napr. súbor programu MS-Word uložený ako „dokument“ – súbor typu „DOC“).

#### *Zrovnanie sekvencií*

V ďalšom kroku je potrebné vykonať samotné zrovnanie sekvencií. Na to je možné využiť rôzne zrovňávacie programy, väčšinou voľne dostupné na internete. Jedným z nich je aj program Clustal-Omega.

>Escco  
MRHPLVMGNWKLNCSRHMVHELVSNLRKELAGVAGCAVIAAPPEMYIDMAKREAEGSHIM  
LGAQNVDLNLSGAFTGETSAAMLKDIGAQYIIGHSERRTYHKSDELIKKFAVLKEQG  
LTPVLCIGETEAEANEAGKTEEVCARQIDAVLKTQGAAAFEGAVIAYPEVWAIGTGKSATP  
AQAQAVHKFIRDHIAKVDANIAEQVIIQYGGSVNASNAAELFAQPDIDGALVGGASLKAD  
AFAVIVKAAEAAKQA

>Nossp  
MRKIVIAGNWKMFKTQAESQEFLKEFLPALEETPQEREVLLCVPFTDLAILSQSLHGSLV  
QLGAQNVDWHAENGAYTGEISGPMLTEIGVRYVIVGHSERRQFFGETDETVNRLQAAQKY  
GLTPILCVGETKQQRDSGETESLIVSQLDKDLINVDQTNLVIAYEPIWAIGTGDTCTTE  
ANRVIGLIRSQLKNSDVPIDIQYGGSVKPNNIDEIMAQPEIDGVLVGGASLEASFARIVNY  
L

>Pyrfu  
MAKLKEPIIAINFKYIEATGKRALEIAKAAEKVYKETGVTIVVAPQLVDLRMIAESVEI  
PVFAQHIDPIKPGSHTGHVLPEAVKEAGAVGTLLNHSENRMILADEAAIRRREEVGLMT  
MVCNNPAVSAAVAALNPDYVAVEPPELIGTGIPVSKAKPEVITNTVELVKVNPEVKVL  
CGAGISTGEDVKKAIELGTVGVLLASGVTKAKDPEKAIWDLVSGIIKE

>Sulso  
MKPPIIIINFKAYENSFGDKAVNLGKKIEKISKEYSVEIILSTPATMIYRMSQEVDLPIY  
AEHVDPVPLGAFTGAILPEMVKDAGAKGTLINHSERRLADEIDDLKRTKGLKSIIC  
VDRYELVYPFSLLKPDAILEPPELIGTGSVSKAKPEVITRAVDEIRKSEGIYLIAGAG  
ITTGEDVYKALKLGAHIGIGVASAVMKAKEPEKVVEDFITSALRAISS

>Sacce  
MARTFFVGGNFKLNGSKQSIKEIVERLNTASIPENVEVICPPATYLDYSVSLVKKPQVT  
VGAQNAYLKGASGAFTGENSDQIKDVGAKWVILGHSERRSYFHEDDKFIADKTFALGQG  
VGVLICIGETLEEKKAGKTLDVVERQLNAVLEEVKDWTNVVVAYEPVWAIGTGLAATPED  
AQDIHASIRKFASKLGDKAASELRLILYGGSANGSNAVTFKDKADVDGFLVGGASLKPEF  
VDIINSRN

>Arath  
AGSGKFFVGGNWKCNGTKDSIAKLISDLNSATLEADVDVVSPPFVYIDQVKSSLTDRID  
ISGQNSWVGKGAFTGEISVEQLKDLGCKWVILGHSERRHVIGEKDEFIGKKAAYALSEG  
LGVIACTIGELEEREAGKTFDVCFAQLKAFADAVPSWDNIVVAYEPVWAIGTGKVASPQQ  
AQEVHVAVRGWLKKNVSEEVASKTRIIYGGSVNGGNSAELAKEEDIDGFLVGGASLGPE  
FATIVNSVTSKKVAA

>Homsa  
MAPSRKFFVGGNWKMNRKQSLGELIGTLNAAKVPADTEVVCAPPTAYIDFARQKLDPKI  
AVAAQNCYKVTNGAFTGEISPGMIKDCGATWVVLGHSERRHVFGESDELIGQKVAHALAE  
GLGVIACIGEKLDEREAGITEKVVFEQTKVIADNVKDWSKVVLAYEPVWAIGTGKTATPQ  
QAQEVEHEKLRGWLKSNSVSDAVAQSTRRIIYGGSVTGATCKELASQPDVDGFLVGGASLKPE  
FVDIINAKQ

**Obr. 3.1.** Vstupný súbor so sekvenciami pripravenými na zrovnávanie. V tomto konkrétnom prípade – podľa zadania – napr. „TIM.txt“. Je to zápis v tzv. FASTA formáte; typ súboru je textový (t.j. iba text). Každá sekvencia je uvedená v prvom riadku znakom „>“, za ktorým sa nachádza jej názov (napr. vhodná skratka, ale môže to byť aj napr. prístupové číslo z databázy, apod.), pričom samotná sekvencia začína na nasledujúcom riadku. To sa opakuje pre všetky sekvencie.

Program Clustal-Omega je využiteľný online ako „nástroj“ cez webstránky Európskeho ústavu pre bioinformatiku (EBI). Prostredie programu Clustal-Omega je užívateľsky prívetivé a na obsluhu jednoduché.

Z jedného a toho istého vstupného súboru (v zmysle zadania; obr. 3.1) sa pripravia dva súbory so zrovnanými sekvenciami:

- (i) súbor typu ALIGNMENT, v ktorom sú sekvencie zrovnané v blokoch po 60 pozíciií, pričom na konci každého bloku sú udané číselné pozície príslušných aminokyselinových zvyškov z jednotlivých sekvencií (súbor „TIM\_aln.txt“ – obr. 3.2;
- (ii) súbor typu Pearson/FASTA, v ktorom sú sekvencie zrovnané vždy každá jedna samostatne a celá v jednom kuse; tento súbor je podobný vstupnému súboru (je to FASTA formát sekvencii), ale s tým rozdielom, že sekvencie sú už zrovnané, t.j. zarovnané na rovnakú (tzv. konsenzuálnu) dĺžku a sú v nich povkladané medzery (súbor: „TIM\_fas.txt“) – obr. 3.3.

V prvom prípade treba v programe zvoliť podmienku cez „Output format“ ako „Clustal with character counts“, kým v druhom prípade je to podmienka „Pearson/FASTA“. Oba súbory sú obsahovo identické, t.j. rozdiel medzi nimi je len formálny – predstavujú rozdielne formy zápisu. Cez podmienku „More options“ a „Order“ je vhodné zvoliť „input order“ (t.j. nie „aligned“), aby sa v zrovnaní dodržalo vstupné poradie sekvencií.

Súbor zrovnania typu „ALIGNMENT“ je vhodnejší pre používateľa, napr. pre ďalšiu analýzu a prípadnú editáciu, ako aj pre prípravu obrázkov. Súbor zrovnania vo formáte „Pearson/FASTA“ potom slúži v ďalšej práci ako vstupný súbor pre výpočet evolučného stromu, resp. evolučných stromov.

Pri práci – editácii – zrovnania vo formáte „ALIGNMENT“, napr. pri identifikácii a zvýrazňovaní určitých špecifických črt jednotlivých sekvencií – ako môžu byť funkčne dôležité aminokyselinové zvyšky alebo nejaké konzervované sekvenčné regióny, apod. – je potrebné sa správne v zrovnaní orientovať. Treba napr. rozlišovať medzi pozíciami v zrovnaní a pozíciami jednotlivých zvyškov v príslušných sekvenciách. Taktiež treba – napr. ak sú zadané nejaké konkrétné aminokyselinové zvyšky – vždy tieto pozície správne identifikovať v sekvencii z daného zdroja (organizmu), aby nedošlo k chybám

a zavádzajúcim interpretáciám. Toto sa týka zvyškov Asn10, Lys12, His95 a Glu165 v sekvencii triózafosfátizomerázy zo *Saccharomyces cerevisiae* – pre konkrétny prípad 7 študovaných triózafosfátizomeráz (tab. 3.1) – zvyšky treba identifikovať s ohľadom na dané aminokyseliny (t.j. N, K, H a E), ich pozície v sekvencii (t.j. nie pozície v zrovnani) a s ohľadom na ich zdroj (*Saccharomyces cerevisiae*). Až potom je možné pristúpiť k prípadnému zvýrazneniu korešpondujúcich zvyškov v danej pozícii pre všetky ostatné zdroje v rámci celého študovaného súboru (obr. 3.4).

Internetové prostredie programu Clustal-Omega na EBI serveri:

<http://www.ebi.ac.uk/Tools/msa/clustalo/>

**Obr. 3.2.** Zrovnanie vo formáte ALIGNMENT – „Clustal with character counts“, t.j. zrovnanie v blokoch s počítaním zvyškov. V tomto konkrétnom prípade – podľa zadania – napr. „TIM\_aln.txt“. Sekvencie sú zrovnané v blokoch po 60 pozíciiach, pričom sú v nich povkladané medzery, aby bola maximalizovaná ich podobnosť. Identické a podobné korešpondujúce zvyšky sú zvýraznené symbolmi „\*“, resp. „:“ a „.“. Čísla vpravo udávajú pozicie koncových aminokyselin v príslušnom bloku a v príslušnej sekvencii.

>Escco  
---MRHPLVMGNWKLNGSRH----MVHELVSNLRK-ELAGVAGCAVIAIPPEMYIDMAK  
REAEKGSHIMLGAQNVDLNLSGAFTGETSAAMLKDIGAQYIIIGHSERRTYHKEDELIAK  
KFAVLKEQGLTPVLCIGETEAENEAGKTEEVCARQIDAVLKTQGAAAFEGAVIAYEPVWA  
IGTGKSATPAQAQAVHKFIRDHIAK-VDANIAEQVIIQYGGSVNASNAAELFAQPDIDGA  
LVGGASLKADAFAVIVKAAEAAKQA---

>Nosspp  
---MRKIVIAGNWKMFKTQA----ESQEFLKEFLPALEETPQEREVLLCVPFTDLAILS  
QLHGSVLQQLGAQNVHWAENGAYTGEISGPMLTEIGVRYVIVGHHSERRQFFGETDETVNL  
RLQAAQKYGLTPILCVGETKQQRDSGETESLIVSQLDKDLIN--VDQTNLVIAYEPIWA  
IGTGDTCTEANRVIGLIRSQLKN-----SDVPIQYGGSVKPNNIDEIMAQPEIDGV  
LVGGASLEAASFARIVNYL-----

>Pyrfu  
MAKLKEPIIAINFKYIEATGKRALEIAKAAEKVYK----ETGVTIVVAPQLVDRMIA  
ESVE---IPVFAQHIDPIKPGSHTGHVLPEAVKEAGAVGTLLNHSENRMILADLEAAIR-  
---RAEEVGMLMTMVCNSNPAS-----AA-----VAALNPDYVAVEPP  
IGTGIPVSKAKPEVITNTVELVKVN-----PEVKVLCGAGISTGEDVKKAIELGTVGV  
LLASGVTKAKDPEKAIWDLVSGIIKE---

>Sulso  
---MKPPIIIINFKAYENSFGDKAVNLGKIEKISK----EYSVEIILSTPATMIYRMS  
QEVD---LPIYAEHVDPVPLGAFTGAILPEMVKDAGAKT LINHSERRLADEIDDVLK-  
---RTKKLGLKSILCVDRYELV-----YP-----FSLLKPDAILEP  
IGTGVSVSKAKPEVITRAVDEIRKS-----EGIYLIAGAGITTGEDVYKALKLGAHGI  
GVASAVMKAKEPEKVVEDFITSALRAISS

>Sacce  
--MARTFFVGGNFKLNGSKQ----SIKEIVERLNT-ASI-PENVEVVICPPATYLDY  
SLVKKPQVTVGAQNAYLKASGAFTGENSDQIKDVGAKWVILGHHSERRSYFHEDDKFIA  
KTKFALGQGVGVILCIGETLEEKKAGKTLVVVERQNAVLEE--VKDWTNVVVAYEPVWA  
IGTGLAATPEDAQDIHASIRKFLASKLGDKAASELRLIYGGSANGSNAVTFKDKADVDGF  
LVGGASLK-PEFVDIINSRN-----

>Arath  
-AGSGKFFVGGNWKCNGTKD----SIAKLISDLNS-ATL-EADDVDVVSPPFVYIDQVK  
SSL-TDRIDISGQNSWVGKGGAFTGEGISVEQLKDLGCKWVILGHHSERRHVIKEDEFIGK  
KAAYALSEGLGVIACIGEKLEEREAGKTFDVCFAQLKAFADA--VPSWDNIVVAYEPVWA  
IGTGKVASPQQAQEVHVAVRGWLKNVSEEVASKTRIYGGSVNGGNSAELAKEEDIDGF  
LVGGASLK-PEFVDIINAKQ-----

>Homsa  
MAPSRKFFVGGNWKMNGRKQ----SLGELIGTLNA-AKV-PADTEVVVCAPPTAYIDFAR  
QKL-DPKIAAAQNCYKVTNGAFTGEISPGMIKDCGATWVVLGHHSERRHVFGESEDELIGQ  
KVAHALAEGLGVIACIGEKLDEREAGITEKVVFEQTKVIADN--VKDWSKVVLAYEPVWA  
IGTGKTATPQQAQEVHEKLRGWLKNVSDAVAQSTRIYGGSVTGATCKELASQPDVDGF  
LVGGASLK-PEFVDIINAKQ-----

**Obr. 3.3.** Zrovanie sekvencií vo formáte Pearson/FASTA. V tomto konkrétnom prípade – podľa zadania – napr. „TIM\_fas.txt“. Je to zápis v tzv. FASTA formáte, t.j. rovnakom, ako sa používa pre prípravu vstupného súboru (obr. 3.1). Rozdiel je v tom, že tu už sú sekvencie zrované, t.j. sú v nich povkladané medzery v snahe maximalizovať podobnosť medzi sekvenciami. Je to formálne odlišný, ale obsahovo identický súbor so zrovaním vo formáte ALIGNMENT (obr. 3.2).

**Obr. 3.4.** Zrovnanie vo formáte ALIGNMENT – „Clustal with character counts“, t.j. zrovnanie v blokoch s počítaním zvyškov, prevedené do textového editora (napr. MS-Word; t.j. súbor je uložený ako dokument). V tomto konkrétnom prípade – podľa zadania – napr. „TIM\_aln.doc“. V súbore je možné robiť formálne úpravy, napr. farebné zvýraznenia funkčne dôležitých aminokyselinových zvyškov, konzervovaných sekvenčných regiónov, apod.

### *Konsenzuálna dĺžka*

Na začiatku má každá sekvencia svoju vlastnú dĺžku vyjadrenú počtom aminokyselinových zvyškov. Pri zrovnávaní sa vyhľadávajú konzervované pozície – buď identické alebo aspoň podobné – ktoré sú usporiadane v zrovnaní pod sebou, t.j. dostanú sa na korešpondujúce pozície. Aby sa maximalizoval počet korešpondujúcich pozícii, do jednotlivých sekvencií sa zrovnávacím programom vkladajú tzv. medzery („gaps“), ktoré sú reprezentované v zrovnanych sekvenciach pomlčkami.

Konsenzuálna dĺžka („consensual length“; CL) je dĺžka sekvencií po ich zrovnani. Minimálne sa rovná dĺžke najdlhšej sekvencie zo súboru sekvencií, ktoré sú zrovnávané, ale len v tom jedinom prípade, ak by sa do nej nevložila ani jedna medzera. Zvyčajne sa pri zrovnávaní sekvencií vložia medzery aj do najdlhšej sekvencie (najmä ak sekvencie nie sú veľmi podobné), preto je konsenzuálna dĺžka spravidla vždy väčšia ako je dĺžka najdlhšej sekvencie.

Pre vzorové zadanie 7 študovaných triózafosfátizomeráz (tab. 3.1) je hodnota konsenzuálnej dĺžky: CL = 269 (napr. obr. 3.2, resp. obr. 3.3).

### *Sekvenčná identita*

Sekvenčná identita („sequence identity“; SI) je vyjadrená ako suma všetkých identických pozícii (program Clustal-Omega ich označuje symbolom „\*“), vztiahnutá k hodnote konsenzuálnej dĺžky. Udáva sa v percentách.

$$SI = \frac{\sum (*)}{CL} \times 100 (\%)$$

Pre vzorové zadanie 7 študovaných triózafosfátizomeráz (tab. 3.1) je hodnota sekvenčnej identity: SI = (20/269) × 100 = 7,44 %.

### *Sekvenčná podobnosť*

Sekvenčná podobnosť („sequence similarity“; SS) je definovaná ako suma všetkých identických, aj podobných pozícii (program Clustal-Omega ich označuje symbolmi „\*“, resp. „:“ a „.“), vztiahnutá k hodnote konsenzuálnej dĺžky. Udáva sa tiež v percentách.

$$SS = \frac{\Sigma (* + : + .)}{CL} \times 100 (\%)$$

Pre vzorové zadanie 7 študovaných triózafosfátizomeráz (tab. 3.1) je hodnota sekvenčnej podobnosti:  $SS = [(20+27+16)/269] \times 100 = (63/269) \times 100 = 23,42\%$ .

Je potrebné si uvedomiť, že hodnota sekvenčnej identity je vždy menšia, maximálne rovná hodnote sekvenčnej podobnosti, pretože sekvenčná podobnosť zahŕňa aj podobné, aj identické aminokyselinové zvyšky v zrovnaní.

Z praktického hľadiska napr. hodnoty SI=7,44% a SS=23,42% pre vzorové zadanie 7 študovaných triózafosfátizomeráz (tab. 3.1) znamenajú, že na 100 pozícii v sekvenčnom zrovnaní je v priemere 92 pozícii, v ktorých sa toleruje zmena aminokyseliny pri súčasnom zachovaní funkcie enzýmu (triózafosfátizomerázy). Inými slovami, sekvenčnú identitu pod 10% možno považovať skôr za nízku, aj keď si je potrebné tiež uvedomiť, že funkčne dôležité zvyšky (ktorých však nebýva veľa – napr. pri enzymoch sú to zvyšky katalytickej mašinérie, prípadne pári ďalších zvykov aktívneho miesta) ostanú pri takejto nízkej hodnote konzervované. Zároveň, aj pri nízkej hodnote sekvenčnej identity, môže byť hodnota sekvenčnej podobnosti relatívne vysoká; čo je aj prípad študovaných 7 triózafosfátizomeráz zo vzorového zadania, kde sa hodnota sekvenčnej podobnosti blíži k 25%.

### *Výpočet evolučných stromov*

Pokiaľ ide o výpočty evolučných stromov, tieto sa počítajú na základe zrovnaných sekvencií. Existuje viacero prístupov, na ktorých sú výpočty evolučných vzťahov založené (napr. metódy UPGMA, Neighbour-joining, Maximum likelihood, Maximum parsimony a Minimum evolution). Pre účely získania prvotných skúseností s uskutočňovaním základnej bioinformatickej analýzy proteínov je dostačujúce oboznámiť sa prípravou evolučných stromov v rámci balíka programu Clustal na serveri EBI, t.j. v rámci programu Simple Phylogeny. Tento ponúka výpočet stromov dvomi

jednoduchšími metódami, a to klastrovacie metódy UPGMA („Unweighted Pair Group Method with Arithmetic Mean“) a Neighbour-joining (metóda spájania susedov). Z nich bude používaná práve Neighbour-joining metóda, ktorá je predvolenou metódou v programe Simple Phylogeny.

Vstupným súborom pre výpočet evolučných stromov je zrovnanie vo formáte Pearson/FASTA (obr. 3.3), z ktorého sa v dvoch postupných krokoch získajú dva evolučné stromy, resp. ich súbory (tab. 3.2):

- (i) súbor stromu založený na uvažovaní pozícii s medzerami v zrovnaných sekvenciách (súbor „TIM\_off.txt“) – do výpočtu sa berú všetky pozície v zrovnaní;
- (ii) súbor stromu založený na ignorovaní pozícii s medzerami v zrovnaných sekvenciách (súbor „TIM\_on.txt“) – do výpočtu sa neberú pozície v zrovnaní, v ktorých sa nachádajú medzery.

V prvom prípade treba v programe zvoliť podmienku „Exclude gaps“ ako „off“ – t.j. treba ju vypnúť, kým v druhom prípade je treba túto podmienku zvoliť ako „on“ – t.j. treba ju zapnúť.

Pre zrovnané sekvencie, ktoré majú vysoký stupeň sekvenčnej podobnosti (identity), t.j. pri zrovnaní bolo do nich vložených málo medzier, stromy počítané s uvažovaním pozícii s medzerami a s ich ignorovaním z toho istého zrovnania si budú veľmi podobné. Pokiaľ však sekvencie vykazujú nízky stupeň vzájomnej podobnosti, t.j. ich zrovnanie obsahuje veľa pozícii s medzerami, stromy môžu byť hodne odlišné. Ide o to, že ak sa v sekvenčnom zrovnaní nachádza príliš veľa pozícii s medzerami, pri výpočte evolučného stromu s ich ignorovaním môže slúžiť ako základ pre výpočet stromu len málo pozícii zrovnania v porovnaní s jeho celou, t.j. konsenzuálnou dĺžkou. To znamená, že pri výpočte evolučného stromu s uvažovaním pozícii s medzerami sa berú do úvahy aj podobnosti, aj rozdiely v sekvenciách, kým pri výpočte stromu založenom na ignorovaní pozícii s medzerami sa pozornosť sústredí na to, čo dané sekvencie spája, t.j. čo majú spoločné (podobné) – čo je konzervované u všetkých sekvencií z daného študovaného súboru – za súčasného možného ignorovania väčšiny rozdielnych črt medzi sekvenciami. Treba pripomenúť, že obidva prístupy majú takto svoje výhody, aj nevýhody.

Internetové prostredie programu Simple Phylogeny na EBI serveri:

[http://www.ebi.ac.uk/Tools/phylogeny/simple\\_phylogeny/](http://www.ebi.ac.uk/Tools/phylogeny/simple_phylogeny/)

The screenshot shows the 'Simple Phylogeny' tool page. At the top, there's a navigation bar with links for EMBL-EBI, Services, Research, Training, Industry, About us, and a search icon. The EMBL-EBI logo includes 'Hinxton'. Below the header, the title 'Simple Phylogeny' is displayed. A sub-header indicates the current location: Tools > Phylogeny > Simple Phylogeny. There are tabs for 'Input form' (selected), 'Web services', and 'Help & Documentation'. On the right, there are 'Feedback' and 'Share' buttons. The main content area is divided into three steps: 'STEP 1 - Enter your multiple sequence alignment', 'STEP 2 - Set your Phylogeny options', and 'STEP 3 - Submit your job'. Step 1 contains a text input field with placeholder text 'Enter or paste a multiple sequence alignment in any supported format.' Step 2 contains dropdown menus for 'TREE FORMAT' (Default), 'DISTANCE CORRECTION' (off), 'EXCLUDE GAPS' (off selected, on available), 'CLUSTERING METHOD' (Neighbour-joining), and 'P.I.M.' (off). Step 3 has a checkbox for 'Be notified by email' and a 'Submit' button.

**Tabuľka 3.2.** Vypočítané súbory evolučných stromov.

TIM_off.txt	TIM_on.txt
( Escco:0.26481, ( Nosspp:0.31843, ( Pyrfu:0.30106, Sulso:0.27483) :0.19220) :0.02373, ( Sacce:0.24481, ( Arath:0.19143, Homsa:0.18760) :0.04340 :0.04189);	( Escco:0.25239, ( Sacce:0.22289, ( Arath:0.18242, Homsa:0.17644) :0.03309) :0.04785) :0.02512, Nosspp:0.30981, ( Pyrfu:0.29665, Sulso:0.26316) :0.21172);

## Úvodná web-stránka programu iTOL (interactive Tree of Life)

<https://itol.embl.de/>

Welcome to iTOL v4  
Interactive Tree Of Life is an online tool for the display, annotation and management of phylogenetic trees.  
Explore your trees directly in the browser, and annotate them with various types of data.

Manage      Annotate      Export

Organize your trees into workspaces and projects, and access them from any browser. Simply drag and drop multiple tree files onto a project to upload them all at once.

18 dataset types. Full control over branch colors, widths and styles. Individually adjustable label fonts, sizes and styles.

Create high quality vector or bitmap figures for your publications. Direct WYSIWYG export of what is displayed on the screen.

Prostredie programu iTOL pre načítanie súboru evolučného stromu:

Upload a new tree

Use this page to upload and visualize a new phylogenetic tree. It should be in a plain text file and in a supported format (Newick, Nexus or PhyloXML). You can also use .jplace files generated by RaxML or plplacer, or .qza trees generated by QIIME 2. Please check the [help pages](#) for detailed instructions.

Trees uploaded anonymously will be stored for 30 days, and are not protected from modifications by other users. If you want to keep them private and protected, or have multiple trees to visualize, we recommend creating an [iTOL personal account](#). If you already have an account, please [login first](#).

Datasets and other annotation should be dragged and dropped directly onto the interactive tree. Please check the [help pages](#) for detailed instructions and dataset template files. Example tree and annotation files [are available for download](#).

Upload a new tree

Tree name:


Paste your tree into the box below, or select a file using the **Tree file** selector. You can also simply drag and drop the tree file onto the page (only a regular plain text file, not QIIME QZA files).

Tree text:


Tree file:

Upload


Prostredie programu iTOL – možnosti zobrazenia evolučného stromu:



Možnosti, pri exportovaní súboru obrázku evolučného stromu:



Pre vzorové zadanie 7 študovaných triózafosfátizomeráz (tab. 3.1) sú obidva evolučné stromy – počítané na základe zrovnania s uvažovaním pozícií s medzerami, aj s ich ignorovaním – znázornené na obr. 3.5. Oba stromy sú v podstate veľmi podobné. Na stromoch sú tri zoskupenia (klastre) triózafosfátizomeráz z týchto organizmov: (i) archeóny – *Pyrococcus furiosus* (Pyrfu) a *Sulfolobus solfataricus* (Sulso); (ii) eukaryoty – *Homo sapiens* (Homsa), *Arabidopsis thaliana* (Arath) a *Saccharomyces cerevisiae* (Sacce); a (iii) baktérie – *Escherichia coli* (Escco) a *Nostoc* sp. PCC 7120 (Nosspp). Sekvencie eukaryotických triózafosfátizomeráz sú si evidentne viac podobné (príbuzné) ako dvojica archeálnych triózafosfátizomeráz, i keď obe dvojice tvoria na evolučných stromoch vzájomne najbližšie príbuzné páry sekvencií.



**Obr. 3.5.** Ilustrácie evolučných stromov. V ľavej časti obrázku sú tzv. kruhové („circular“) typy a v pravej časti sú tzv. pravouhlé („rectangular“) typy zobrazenia evolučných stromov. V prvom prípade je dôležitá aj samotná dĺžka vetiev (je tam udaná mierka, ktorej dĺžka udáva zmienu 0,1 aminokyseliny na dané miesto), kým v druhom prípade dĺžka vetiev je len pomerná (jej dĺžka nemá reálny význam). Zobrazené súbory sú konkrétnie súbory pre vzorové zadanie 7 študovaných triózafosfátizomeráz, t.j. (a) „TIM\_off.txt“ a (b) „TIM\_on.txt“.

## 4. HCA – metóda analýzy hydrofóbnych klastrov

Metóda analýzy hydrofóbnych klastrov – HCA („Hydrophobic Cluster Analysis“) – bola vyvinutá a predstavená ako nová metóda na porovnanie a zrovnávanie sekvencií proteínov v roku 1987 (obr. 4.1). Je to metóda použiteľná iba na aminokyselinové sekvencie. Jej podstatou je dvoj-rozmerná reprezentácia sekvencie proteínu, v ktorej obraze sú určené hydrofóbne klastre; pričom tieto dvoj-rozmerné vzory rozloženia hydrofóbnych aminokyselinových zvyškov slúžia ďalej na porovnanie sekvencií.

K výhodám metódy HCA patrí, že: (i) nevyžaduje k svojej realizácii výkonnú výpočtovú techniku; (ii) je vhodná aj na analýzu vzdialene príbuzných proteínov (t.j. pri vysokom stupni ich divergovanosti); (iii) je senzitívnejšia ako bežné zrovnávacie programy (napr. Clustal-Omega, apod.); a (iv) možno ju využiť aj pri absencii údajov o terciárnej štruktúre študovaných proteínov. Na druhej strane si však jej spoľahlivé využitie vyžaduje získať väčšiu rutinu a prax, ako pri práci s bežnými programami na zrovnávanie sekvencií. Na obr. 4.2 sú titulné stránky publikácií, v ktorých bola HCA metóda predstavená po niekoľkých rokoch úspešného používania.

Volume 224, number 1, 149–155

FEB 05299

November 1987

### Hydrophobic cluster analysis: an efficient new way to compare and analyse amino acid sequences

C. Gaboriaud, V. Bissery, T. Benchetrit<sup>+</sup> and J.P. Mornon

Groupe Cristallographie et Simulations Interactives des Macromolécules Biologiques, Laboratoire de

Minéralogie-Cristallographie, CNRS U409, Universités P6 et P7, T16, 4 place Jussieu, 75252 Paris Cedex 05 and

<sup>+</sup>Département de Chimie Organique, UA498 CNRS, U266 INSERM, UER des Sciences Pharmaceutiques et Biologiques,

4 avenue de l'Observatoire, 75006 Paris, France

Received 24 September 1987

A new method for comparing and aligning protein sequences is described. This method, hydrophobic cluster analysis (HCA), relies upon a two-dimensional (2D) representation of the sequences. Hydrophobic clusters are determined in this 2D pattern and then used for the sequence comparisons. The method does not require powerful computer resources and can deal with distantly related proteins, even if no 3D data are available. This is illustrated in the present report by a comparison of human haemoglobin with leghaemoglobin, a comparison of the two domains of liver rhodanese (thiosulphate sulphurtransferase) and a comparison of plastocyanin and azurin.

Protein sequence comparison; Conformation homology; Protein structure prediction

**Obr. 4.1.** Úvodná publikácia vo *FEBS Letters* z roku 1987 o metóde HCA.

## Hydrophobic cluster analysis: procedures to derive structural and functional information from 2-D-representation of protein sequences

L Lemesle-Varloot<sup>1</sup>, B Henrissat<sup>2</sup>, C Gaboriaud<sup>1,3</sup>, V Bissery<sup>1</sup>, A Morgat<sup>1,4</sup>, JP Mornon<sup>\*1</sup>

<sup>1</sup>Laboratoire de Minéralogie-Cristallographie, Universités Paris 6 and 7, CNRS URA 09, T16, 4 place Jussieu, 75252 Paris Cedex 05;

<sup>2</sup>Centre de Recherches sur les Macromolécules Végétales, CNRS, Université Joseph Fourier, BP 53X, 38041 Grenoble;

<sup>3</sup>Institut de Chimie des Substances Naturelles, CNRS, 91190 Gif-sur-Yvette;

<sup>4</sup>Service de Modélisation Moléculaire, Centre de Recherches Rhône Poulenc Santé, 13 quai Jules Guesde, 94403 Vitry-sur-Seine Cedex, France

(Received 28 June 1990; accepted 11 July 1990)

**Summary** – Hydrophobic cluster analysis (HCA) [15] is a very efficient method to analyse and compare protein sequences. Despite its effectiveness, this method is not widely used because it relies in part on the experience and training of the user. In this article, detailed guidelines as to the use of HCA are presented and include discussions on: the definition of the hydrophobic clusters and their relationships with secondary and tertiary structures; the length of the clusters; the amino acid classification used for HCA; the HCA plot programs; and the working strategies. Various procedures for the analysis of a single sequence are presented: structural segmentation, structural domains and secondary structure evaluation. Like most sequence analysis methods, HCA is more efficient when several homologous sequences are compared. Procedures for the detection and alignment of distantly related proteins by HCA are described through several published examples along with 2 previously unreported cases: the  $\beta$ -glucosidase from *Ruminococcus albus* is clearly related to the  $\beta$ -glucosidases from *Clostridium thermocellum* and *Hansenula anomala* although they display a reverse organization of their constitutive domains; the alignment of the sequence of human GTPase activating protein with that of the *Crk* oncogene is presented. Finally, the pertinence of HCA in the identification of important residues for structure/function as well as in the preparation of homology modelling is discussed.

protein sequences / protein structure / alignment / sequence comparisons / secondary structure / homology detection

CMLS, Cell. mol. life sci. 53 (1997) 621–645  
1420-682X/97/080621-25 \$ 1.50 + 0.20/0  
© Birkhäuser Verlag, Basel, 1997

**CMLS Cellular and Molecular Life Sciences**

## Review

### Deciphering protein sequence information through hydrophobic cluster analysis (HCA): current status and perspectives


I. Callebaut<sup>a</sup>, G. Labesse<sup>a</sup>, P. Durand<sup>a</sup>, A. Poupon<sup>a</sup>, L. Canard<sup>a</sup>, J. Chomilier<sup>a</sup>, B. Henrissat<sup>b</sup>  
and J. P. Mornon<sup>a,\*</sup>

<sup>a</sup>Systèmes Moléculaires et Biologie Structurale, LMCP, CNRS URA 09, UP6/UP7, Case 115, 4 place Jussieu,  
F-75252 Paris Cedex 05 (France), Fax +33 1 44 27 37 85, e-mail: Isabelle.Callebaut@lmcp.jussieu.fr

<sup>b</sup>Centre de Recherches sur les Macromolécules Végétales\*\*, CNRS, BP53, F-38041 Grenoble Cedex 9 (France)

**Obr. 4.2.** Titulné stránky publikácií v časopisoch *Biochimie* a *Cell. Mol. Life Sci.* z rokov 1990, resp. 1997, v ktorých boli sumarizované pokroky v používaní metódy HCA.


Teoretické základy a postup jednotlivých krokov vedúcich k získaniu HCA obrazu sekvencie proteínu je vysvetlený na obr. 4.3.



**Obr. 4.3.** Popis jednotlivých krokov vedúcich k získaniu HCA obrazu sekvencie proteínu. Všeobecná aminokyselinová sekvencia (lineárna; 1D) je znázornená s farebne zvýraznenými hydrofóbnymi zvyškami. Vybraným aminokyselinám (Gly, Pro, Thr a Ser) sú priradené špeciálne symboly. Všetky aminokyselinové zvyšky sú rozdelené na hydrofóbne (hodnota „1“) a hydrofilné (hodnota „0“). Sekvencia je následne zapísaná (navinutá) na špirálu a zobrazená pozdĺž valca, ktorý je potom prerezaný paralelne so svojou osou (2D). Takto vzniknutý dvojrozmerný diagram je duplikovaný v snahe obnoviť celkové okolité prostredie každej aminokyseliny. Hydrofóbne zvyšky nie sú distribuované náhodne, ale tvoria klastre, ktoré sú zvýraznené programom pomocou obkresenia. Pozicie hydrofóbnych klastrov môžu korešpondovať s pozíciami pravidelných elementov sekundárnej štruktúry ( $\alpha$ -helixy a  $\beta$ -vlákna), čo je znázornené na korešpondujúcej experimentálnej terciárnej štruktúre (3D).

Upravené podľa Callebaut et al. (1997).

Okrem identifikácie prípadných korešpondencií medzi sekvenciami vzdialene príbuzných proteínov, možno metódu HCA – ale len v určitom zjednodušenom priblížení – využiť aj na čiastočnú predikciu sekundárnej štruktúry proteínov. Je to v dôsledku toho, že tvary hydrofóbnych klastrov môže korešpondovať s pravidelnými elementami sekundárnej štruktúry, ako sú  $\alpha$ -helixy a  $\beta$ -vlákna. Horizontálne pretiahnutý tvar hydrofóbneho klastra môže indikovať prítomnosť  $\alpha$ -helixu, kým vertikálne pretiahnutý tvar klastra môže byť spojený s existenciou  $\beta$ -vlákna v štruktúre proteínu (obr. 4.4).



**Obr. 4.4.** Ilustrácia horizontálneho a vertikálneho hydrofóbneho klastra v HCA obrazu sekvencie proteínu, ktorá môže naznačovať  $\alpha$ -helix, resp.  $\beta$ -vlákno v jeho štruktúre.

Pre lepšiu vizualizáciu a uľahčenie identifikácie korešpondencií medzi analyzovanými sekvenciami proteínov, štyri vybrané aminokyseliny majú špeciálne symboly: glycín – ♦; prolín – ★; treonín – □; a serín – ▢.


V metóde HCA je 20 aminokyselín rozdelených do dvoch hlavných tried: (i) hydrofóbne; a (ii) hydrofilné a/alebo indiferentné k ich prostrediu. Toto rozdelenie je urobené arbitrážne, kvôli zjednodušeniu a možnosti analyzovať potenciálne hydrofóbne klastre, aj keď nie celkom odpovedá realite. V skutočnosti má každá aminokyselina svoju vlastnú hodnotu hydrofóbnosti, resp. hydrofilnosti, a to aj v závislosti od podmienok merania.

Pre globulárne proteíny platí, že prevažne hydrofóbne aminokyselinové zvyšky tvoria vnútorné jadro proteínu, kým prevažne hydrofilné zvyšky tvoria povrch (ochrana jadra pred vodou a iónmi). Toto rozdelenie je dôsledkom entropických a entalpickej súčasti, ktoré vedú proces k tvorbe hydrofóbnych

klastrov (interakcií) vo vnútorných oblastiach proteínu. Hydrofóbne interakcie sú jedným zo základov udržiavania terciárnej štruktúry proteínu. Hydrofóbne aminokyseliny sú uprednostňované vo vnútorných častiach pravidelných elementov sekundárnej štruktúry ( $\alpha$ -helix a  $\beta$ -list), pričom sa menej vyskytujú v nepravidelných elementoch sekundárnej štruktúry (slučky a ohyby).

Na základe pozorovaní, skúseností a výpočtov bolo 20 aminokyselín rozdelených v metóde HCA nasledovne:

- (i) silne hydrofóbne aminokyseliny (Val, Ile, Leu a Phe) – s hodnotou HCA: „1“ – ktoré sú hnacou silou tvorby hydrofóbnych, vnútorných častí elementov sekundárnej štruktúry;
- (ii) stredne hydrofóbne aminokyseliny (Met, Trp a Tyr) – rovnako s hodnotou HCA: „1“ – každá so svojimi špecifickými vlastnosťami;
- (iii) všetky ostatné aminokyseliny (Gly, Ala, Ser, Thr, Cys, His, Pro, Asp, Glu, Asn, Gln, Lys a Arg) – s hodnotou HCA: „0“ – sú považované za hydrofilné, resp. nie hydrofóbne.



**Obr. 4.5.** Predikcia medzidoménovej oblasti proteínu – úsek bohatý na treonín a serín.

Aminokyselina prolín, ktorá často prerušuje sekundárne štruktúry, je považovaná za zvyšok prerušujúci hydrofóbne klastre. Cysteín nepreruší klastrové správanie aminokyselín v proteínoch, ale tvorí S-S mostíky. Zvyšky treonín a serín často maskujú svoju polaritu a ich zvýšená prítomnosť môže signalizovať hraničné oblasti domén v proteínoch (obr. 4.5). Kyselina asparágová a kyselina glutámová sú na opačnej strane spektra ako valín, leucín, izoleucín a fenylalanín.

Metóda HCA – príprava HCA obrazu sekvencie proteínu – je dostupná na internete: <https://mobyle.rpbs.univ-paris-diderot.fr/>; v rámci „Programs“ postupom cez „Structure“ – „Prediction“ – „2D Structure“ – „HCA“.

The screenshot shows the RPBS Web Portal homepage. The top navigation bar includes links for 'set email', 'sign-in', 'activate', 'sign-out', and 'refresh workspace'. The main menu on the left has sections for 'Programs' (Drugs, Peptides, Sequence, Structure, Test), 'Tutorials' (Data formats, Howtocte, Overview, PDBlInput, Policy, Registration, Stepbystep), and 'Services Help Pages' (BCSearch, FAF-Drugs4, iPocket, Frog2, HHAlign-Kbest, InterEvDock2, MTIAutoDock/MTIOpenScreen, PatchSearch, Proteo3Dnet, PCE, PEP-FOLD, PEP-FOLD3, PEP-SiteFinder, pepATTRACT, SABBAC, SAFlag, SolvPep, Yakusa). The central content area features a 'Welcome to Mobyle, a portal for bioinformatics analyses' message. Below it is a list of maintenance logs from various dates, mostly warnings about downtime. At the bottom, there are logos for BFA, Inserm, Paris Diderot, IBISA, and ifb.

This screenshot shows the RPBS Web Portal with the search term 'HCA' entered. The main content area displays the 'HCA 1.0.2' analysis page, which is described as 'Hydrophobic Cluster Analysis'. It features a 'Run', 'Reset', and 'Help pages' button. The interface includes an 'Input Data' section with a 'Query' field containing 'paste', 'db', and 'upload' options, and an 'Options' section with 'Format' set to 'PDF format' and 'Black and white' set to 'No'. A note at the bottom cites a 1997 review by Callebaut et al. about HCA. On the left, a sidebar highlights the 'Structure' section under 'Programs' with several arrows pointing to it, indicating its importance or relevance to the analysis shown.

Nasledujúci príklad ilustruje prípravu HCA obrazu sekvencie polygalakturonázy z *Aspergillus niger*, sekvenčia ktorej je uložená v databáze UniProt pod prístupovým číslom: P26214.

```
>sp|P26214|PGLR2 ASPNG Endopolygalacturonase-2 OS=Aspergillus niger
```

```
MHSFASLLAYGLVAGATFASASPIEARDSCFTTAAAKAGKAKCSTITLNNIEVPAGTT
LDLTGLTSGTKVI FEGTTTFQYEEWAGPLISMSGEHITVTGASGLINCDGARWWDGKGT
SGKKPKFFYAHGLDSSSITGLNIKNTPLMAFSVQANDITFTDVTINNADGDTQGGHNTD
AFDVGNVGVNIIKPWVHNQDDCLAVNSGENIWFTEGGTCIGGGHGLSIGSVGDRSNNVVKN
VTIEHSTVSNSENAVRIKTISGATGSVSEITYSNIVMSGISDYGVVIQQDYEDGKPTGKP
TNGVTIQDVKLESVTGSVDSGATEIYLLCGSGSCSDWTWDDVKVTGGKKSTACKNFPSC
SC
```

Sekvenciu – ako text – je potrebné vložiť ako vstupný údaj („query“) a výsledky, t.j. HCA obraz sekvencie proteínu, je možné získať ako „PDF“ alebo „PostScript“ súbor, a to budť v čierno-bielej verzii alebo farebom prevedení.

The screenshot shows the HCA 1.0.2 web application interface. At the top, there is a navigation bar with tabs: Welcome, Forms, Data Bookmarks, Jobs, and Tutorials. Below the navigation bar, there is a search bar and a link to [more]. On the left side, there is a sidebar with a tree view of available programs and services. The 'Programs' section includes categories like Drugs, Peptides, Sequence, Structure, Analysis, Complexes, Edition, Homology, Pockets, Prediction, 2D\_structure, HCA, PPP, psipred, 3D\_structure, MIR, SimilaritySearch, Simulation, Superposition, and Test. The 'Tutorials' section includes links to Data formats, Howto, Overview, PDBInput, Policy, Registration, and Stepbystep. The 'Services Help Pages' section includes a link to BCSearch. The main content area is titled 'HCA 1.0.2' and 'Hydrophobic Cluster Analysis'. It features a large input field labeled 'Query' with three tabs: 'paste', 'db', and 'upload'. Below the input field, there is a button to 'Run' and a 'Help pages' link. The input field contains the protein sequence provided in the text above. Below the input field, there is an 'Options' section with dropdown menus for 'Format' (PDF format, PostScript format) and 'Black and white' (Yes, No). There are also three separate sections at the bottom for different output formats: PDF format (Black and white Yes), PostScript format (Black and white No), and PostScript format (Black and white Yes).

**RPBS Web Portal**

(guest)  
[set email](#) [sign-in](#) [sign-out](#)  
[refresh workspace](#)

Search [more] Welcome Forms Data Bookmarks Jobs Tutorials

Overview HCA - 10/26/20 20:22:30 [remove job](#) HCA - 10/26/20 20:26:56 [remove job](#)

<https://mobyle.rpbs.univ-paris-diderot.fr/data/jobs/HCA/H02537102804899>

get help back to form remove job download

results

HCA Results

Secondary structure assignment (Text)

HCA.pdf

query data seq Denovia by Luc Caudr



Denovia by Luc Caudr

**RPBS Web Portal**

(guest)  
[set email](#) [sign-in](#) [sign-out](#)  
[refresh workspace](#)

Search [more] Welcome Forms Data Bookmarks Jobs Tutorials

Overview HCA - 10/26/20 20:22:30 [remove job](#)

<https://mobyle.rpbs.univ-paris-diderot.fr/data/jobs/HCA/M01679281352043>

get help back to form remove job download

results

HCA Results

Secondary structure assignment (Text)

HCA.pdf

query data seq Denovia by Luc Caudr




Denovia by Luc Caudr

Vstupná sekvencia:

>sp|P26214|PGLR2 ASPNG Endopolygalacturonase-2 OS=Aspergillus niger

MHSFASLLAYGLVAGATFASASPPIEARDSCFTTAAAKAGKAKCSTITLNNIEVPAGTT  
LDLTGLTSGTKVIFEGTTTFQYEEWAGPLISMSGEHITVTGASGHLINCDGARWDGKGT  
SGKKPKFFYAHGLDSSSITGLNIKNTPLMAFSVQANDITFTDVTINNADGDTQGGHNTD  
AFDVGNSGVNIICKPVHNQDDCLAVNSGENIWTGGTCIGGHGLSIGSVGDRSNNVVKN  
VTIEHSTVSNSENAVRIKTISGATGSVSEITYSNIVMSGISDYGVVIQQDYEDGKPTGKP  
TNGVTIQDVKLESVTGSVDSGATEIYLLCGSGSCSDTWDDVKVTGGKSTACKNFPSC  
SC

Výsledný HCA obraz sekvencie v čierno-bielej a farebnej verzii:



## 5. BLAST – nástroj na vyhľadávanie sekvenčných podobností

Úvodná web-stránka nástroja BLAST:

<https://blast.ncbi.nlm.nih.gov/>

The screenshot shows the NCBI BLAST homepage. At the top, there's a navigation bar with the NIH logo, U.S. National Library of Medicine, NCBI National Center for Biotechnology Information, and a 'Sign in to NCBI' link. Below the navigation is the 'BLAST®' logo and a horizontal menu with 'Home', 'Recent Results', 'Saved Strategies', and 'Help'. A 'NEWS' sidebar on the left has a message about RefSeq Select databases and a date 'Tue, 13 Oct 2020 12:00:00 EST'. A 'More BLAST news...' link is also present.

**Basic Local Alignment Search Tool**

BLAST finds regions of similarity between biological sequences. The program compares nucleotide or protein sequences to sequence databases and calculates the statistical significance. [Learn more](#)

**Web BLAST**

Nucleotide BLAST (nucleotide ▶ nucleotide)      blastx (translated nucleotide ▶ protein)      tblastn (protein ▶ translated nucleotide)      Protein BLAST (protein ▶ protein)

**BLAST Genomes**

Enter organism common name, scientific name, or tax id      Human      Mouse      Rat      Microbes      Search

**Standalone and API BLAST**

Download BLAST      Use BLAST API      Use BLAST in the cloud

**Specialized searches**

SmartBLAST	Primer-BLAST	Global Align	CD-search
Find proteins highly similar to your query	Design primers specific to your PCR template	Compare two sequences across their entire span (Needleman-Wunsch)	Find conserved domains in your sequence
IgBLAST	VecScreen	CDART	Multiple Alignment
Search immunoglobulins and T cell receptor sequences	Search sequences for vector contamination	Find sequences with similar conserved domain architecture	Align sequences using domain and protein constraints
MOLE-BLAST			
Establish taxonomy for uncultured or environmental sequences			

BLAST is a registered trademark of the National Library of Medicine

Support center      Mailing list      You

NCBI  
National Center for Biotechnology Information, U.S. National Library of Medicine  
8600 Rockville Pike, Bethesda MD, 20894 USA

Policies and Guidelines | Contact

BLAST („Basic Local Alignment Search Tool“) je internetový nástroj, ktorý hľadá regíony lokálnej podobnosti medzi sekvenciami. Program porovnáva nukleotidové alebo aminokyselinové sekvencie k sekvenčným databázam a počíta štatistickú významnosť zhody. BLAST možno použiť na odvodenie funkčných a evolučných vzájomných vzťahov medzi sekvenciami, ako aj ako pomôcku pri identifikovaní génových a proteínových rodín. BLAST bol originálne vyvinutý a predstavený vedeckej komunite v roku 1990; jeho domovská web-stránka je v rámci systému Entrez na serveri NCBI.

K základnému programovému vybaveniu patria štandardné typy BLASTn a BLASTp, ktoré prezerajú nukleotidové databázy s použitím záujmovej sekvencie („query“) nukleotidovej, resp. proteínové databázy s použitím záujmovej sekvencie („query“) aminokyselinovej. Ako *query* je označovaná sekvencia, o BLAST ktorej je záujem, t.j. možno ju považovať aj za dopytovu sekvenciu, prípadne žiadanku. K ďalším základným programom patria aj programy BLASTx a tBLASTn, ktoré prehľadávajú proteínové databázy použijúc preložený nukleotidový dopyt, resp. preložené nukleotidové databázy použijúc aminokyselinový dopyt. Prostredie BLAST ponúka aj rôzne špecializované vyhľadávania.

### *Proteínový BLAST*

Samotný proteínový BLAST možno realizovať okrem základného štandardného algoritmu aj ako tzv. PSI-BLAST („Position-Specific Iterated“), PHI-BLAST („Pattern Hit Initiated“) a DELTA-BLAST („Domain Enhanced Lookup Time Accelerated“).

BLAST ponúka veľké možnosti, ako zamerať prehľadávanie databáz so známymi sekvenciami. Je možné blastovať *query*, ktorá predstavuje celú sekvenciu alebo len jej časť. Tiež je v ponuke výber databáz – ako prednastavená je databáza *Non-redundant protein sequences* (označená ako „nr“), ktorej voľba by mala zabezpečiť, že získané výsledky nebudú zbytočne redundantné, t.j. nadbytočné (duplicítne) v dôsledku viacerých záznamov pre tú istú sekvenciu, napr. aj pre ten istý záznam v databázach GenBank a UniProt. Ďalšou skvelou možnosťou je ponuka zamerať prehľadávanie len

na vybraný taxón, resp. taxóny (prípadne aj na celé ríše *Bacteria*, *Archaea* alebo *Eucarya*), ako aj možnosť ich vylúčenia z prehľadávania.

Dôležitým parametrom je „Max target sequences“, ktorým je možné obmedziť počet sekvencií, ktoré budú zobrazené vo výsledkoch; ich hodnotu je možné nastaviť od 10 do 5 000 (v nedávnej dobe to bolo ešte 20 tisíc).

Pri opakovanom blastovaní s tou istou sekvenciou, ale pri menení podmienok a parametrov, je veľmi výhodnou funkciou možnosť „Show results in a new window“, t.j. možnosť zobraziť výsledky v novom okne monitoru.

Výsledky, ktoré poskytuje BLAST, sú štandardne zložené z troch, resp. štyroch častí: (i) opisy („descriptions“); (ii) grafický súhrn („graphic summary“); (iii) zrovnania („alignments“); a v súčasnosti aj (iv) taxonómia („taxonomy“). Za jeden z najdôležitejších výsledkov BLASTu možno považovať potenciálnu identifikáciu konzervovaných domén v sekvencii blastovaného proteínu, najmä, ak je málo informácií o jeho možnej funkcii.

Štatistická významnosť zhody sa udáva ako skóre zrovnania – hodnota S („alignment score“), ktorého vyššia hodnota znamená vyššiu podobnosť medzi sekvenciami. Ďalšou hodnotou charakterizujúcou významnosť zásahu pri blastovaní je hodnota E („expectation“), ktorá predstavuje počet rôznych zrovnaní so skóre ekvivalentným alebo lepším ako to, pri ktorom sa očakáva, že sa pri vyhľadávaní v databáze vyskytne náhodne. V prípade hodnoty E platí, že čím nižšia je jeho hodnota, tým vyššia (významnejšia) je hodnota S, a teda aj samotného zrovnania. Pre najvýznamnejšie zásahy sa E hodnota limitne blíži k nule, naopak môže dosahovať hodnoty až v jednotkách.

V samotných zrovaniach BLASTu sa dopytová sekvencia (query) nachádza v 1. riadku, kým zachytená sekvencia (označovaná ako „subject“ – skr. „sbjct“) sa nachádza v 3. riadku. V strednom riadku medzi *query* a *subject* sú zvýraznené identické („identities“) a podobné („positives“) aminokyselinové zvyšky, pričom prvé sú udávané písmenom danej identickej aminokyseliny a druhé znamienkom plus (+). Dôležité je uvedomiť si aj to, že tzv. prvý zásah, („the first hit“) je spravidla samotná query, t.j. blastovaná sekvencia (ak už pochádza z databáz); pokial sa teda neblastuje s unikátnou (novou) sekvenciou, ktorá sa v databázach ešte nenachádza.

## Úvodná web-stránka pre proteínový BLAST:

NIH U.S. National Library of Medicine > NCBI National Center for Biotechnology Information

## BLAST® > blastp suite

### Standard Protein BLAST

[blastn](#) [blastp](#) [blastx](#) [tblastn](#) [tblastx](#)

**Enter Query Sequence**

Enter accession number(s), gi(s), or FASTA sequence(s) [?](#) [Clear](#) [Query subrange](#) [?](#)

From  To

Or, upload file [Prehľadávat...](#) Nie je zvolený súbor. [?](#)

Job Title  Enter a descriptive title for your BLAST search [?](#)

Align two or more sequences [?](#)

**Choose Search Set**

Database Non-redundant protein sequences (nr) [?](#)

Organism  Enter organism name or id—completions will be suggested [?](#)  exclude [+](#)  
Optional Enter organism common name, binomial, or tax id. Only 20 top taxa will be shown. [?](#)

Exclude  Models (XML/XP)  Non-redundant RefSeq proteins (WP)  Uncultured/environmental sample sequences  
Optional

**Program Selection**

Algorithm  Quick BLASTP (Accelerated protein-protein BLAST)  
 **blastp** (protein-protein BLAST)  
 PSI-BLAST (Position-Specific Iterated BLAST)  
 PHI-BLAST (Pattern Hit Initiated BLAST)  
 DELTA-BLAST (Domain Enhanced Lookup Time Accelerated BLAST)

Choose a BLAST algorithm [?](#)

**BLAST** Search database nr using Blastp (protein-protein BLAST)  
 Show results in a new window

[Algorithm parameters](#)

- načítanie sekvencie – query:

**BLAST®** Basic Local Alignment Search Tool

NCBI/ BLAST/ blastp suite Standard Protein BLAST

blastn blastp blastx tblastn tblastx

Enter Query Sequence  
 Enter accession number(s), g(i)s, or FASTA sequence(s)

Or, upload file

Job Title  Enter a descriptive title for your BLAST search

Align two or more sequences

**Choose Search Set**

Database Non-redundant protein sequences (nr)

Organism Optional Enter organism name or id—completions will be suggested   Exclude  Enter organism common name, binomial, or tax id. Only 20 top taxa will be shown.

Exclude Optional  Models (XM/XP)  Uncultured/environmental sample sequences

Entrez Query Optional Enter an Entrez query to limit search

**Program Selection**

Algorithm  blastp (protein-protein BLAST)  
 PSI-BLAST (Position-Specific Iterated BLAST)  
 PHI-BLAST (Pattern Hit Initiated BLAST)  
 DELTA-BLAST (Domain Enhanced Lookup Time Accelerated BLAST)  
 Choose a BLAST algorithm

**BLAST** Search database Non-redundant protein sequences (nr) using Blastp (protein-protein BLAST)  
 Show results in a new window

Algorithm parameters

- výber databázy:

NCBI/ BLAST/ blastp suite Basic Local Alignment Search Tool Standard Protein BLAST

blastn blastx blastx tblastn tblastx

Enter Query Sequence  
From \_\_\_\_\_ To \_\_\_\_\_

Or, upload file Prehľadávať...  
Job Title  
Enter a descriptive title for your BLAST search  
Align two or more sequences

Choose Search Set  
Database: Non-redundant protein sequences (nr)  
Organism: Non-redundant protein sequences (nr)  
Optional: Reference proteins (refseq\_protein)  
UniProtKB/Swiss-Prot(swissprot)  
Patented protein sequences(pat)  
Protein Data Bank proteins(pdb)  
Metagenomic proteins(env\_nr)  
Exclude: tax id. Only 20 top taxa will be shown.  
Entrez Query: Enter an Entrez query to limit search

Program Selection  
Algorithm: blastp (protein-protein BLAST)  
PSI-BLAST (Position-Specific Iterated BLAST)  
PHI-BLAST (Pattern Hit Initiated BLAST)  
DELTA-BLAST (Domain Enhanced Lookup Time Accelerated BLAST)  
Choose a BLAST algorithm

**BLAST** Search database Non-redundant protein sequences (nr) using Blastp (protein-protein BLAST)  
Show results in a new window

**Algorithm parameters**

- výber parametra maximálneho počtu zobrazených sekvencií:

Program Selection  
Algorithm: blastp (protein-protein BLAST)  
PSI-BLAST (Position-Specific Iterated BLAST)  
PHI-BLAST (Pattern Hit Initiated BLAST)  
DELTA-BLAST (Domain Enhanced Lookup Time Accelerated BLAST)  
Choose a BLAST algorithm

**BLAST** Search database Non-redundant protein sequences (nr) using Blastp (protein-protein BLAST)  
Show results in a new window

**Algorithm parameters**

General Parameters  
Max target sequences: 100 (maximum number of aligned sequences to display)  
Short queries: 100 (automatically adjust parameters for short input sequences)  
Expect threshold: 500  
Word size: 10000  
Max matches in a query range: 0

Scoring Parameters  
Matrix: BLOSUM62  
Gap Costs: Existence: 11 Extension: 1  
Compositional adjustments: Conditional compositional score matrix adjustment

Filters and Masking  
Filter: Low complexity regions  
Mask: Mask for lookup table only, Mask lower case letters

**BLAST** Search database Non-redundant protein sequences (nr) using Blastp (protein-protein BLAST)  
Show results in a new window

Výsledky: (i) opisy; (ii) grafický súhrn; (iii) zrovnania; a (iv) taxonómia:

(i)

U.S. National Library of Medicine  
National Center for Biotechnology InformationLog In

BLAST® » blastp suite » results for RID-6C2B3GEK016

[Home](#) [Recent Results](#) [Saved Strategies](#) [Help](#)

[Edit Search](#) [Save Search](#) [Search Summary](#)

**Job Title** Protein Sequence

**RID** [6C2B3GEK016](#) Search expires on 03-10 17:16 pm [Download All](#)

**Program** BLASTP [?](#) [Citation](#)

**Database** nr [See details](#)

**Query ID** lcl|Query\_27272

**Description** None

**Molecule type** amino acid

**Query Length** 718

**Other reports** [Distance tree of results](#) [Multiple alignment](#) [MSA viewer](#) [?](#)

[How to read this report?](#) [BLAST Help Videos](#) [Back to Traditional Results Page](#)

**Filter Results**

**Organism** only top 20 will appear  exclude

Type common name, binomial, taxid or group name

[+ Add organism](#)

**Percent Identity**  to

**E value**  to

**Query Coverage**  to

[Filter](#) [Reset](#)

**Descriptions** [Graphic Summary](#) [Alignments](#) [Taxonomy](#)

[Download](#) [Manage Columns](#) [Show 100](#) [?](#)

**Sequences producing significant alignments**

select all 100 sequences selected

	Description	Max Score	Total Score	Query Cover	E value	Per. Ident	Accession
<input checked="" type="checkbox"/>	RecName:Full=Cyclomaltoextrin glucanotransferase [AltName: Full=Cyclodextrin-glycosyltransferase; Short=CGTase; Flags_Precursor]	1465	1465	100%	0.0	100.00%	P30920_1
<input checked="" type="checkbox"/>	alpha-amylase [Paenibacillus xylanedens]	1464	1464	100%	0.0	99.86%	WP_154960227_1
<input checked="" type="checkbox"/>	alpha-amylase [Paenibacillus xylanedens]	1463	1463	100%	0.0	99.72%	WP_154984647_1
<input checked="" type="checkbox"/>	alpha-amylase [Paenibacillus polysaccharolyticus]	1460	1460	100%	0.0	99.58%	WP_090917495_1
<input checked="" type="checkbox"/>	alpha-amylase [Paenibacillus xylanedens]	1459	1459	100%	0.0	99.30%	WP_145415056_1

(ii)


The screenshot shows the 'Graphic Summary' tab selected. At the top, there are tabs for 'Descriptions', 'Graphic Summary' (selected), 'Alignments', and 'Taxonomy'. Below these are buttons for 'hover to see the title', 'click to show alignments', and 'Show Conserved Domains'. A color scale for 'Alignment Scores' ranges from < 40 (black) to >= 200 (red). The main area displays a 'Query seq.' with positions 100, 200, 300, 400, 500, 600, and 700 marked. Annotations include 'active site' at position 200, 'catalytic site' at 300, 'Ca binding site' at 350, 'starch-binding site 1' at 550, and 'starch-binding site 2' at 650. A green box highlights the 'AmyAc\_family superfamily'. Below the sequence, specific hits are listed: AmyAc\_Amylase\_1aa, AmyAc\_Amylase\_C\_mx, AmyAc\_IPT\_CGID, and AmyAc\_IPT\_swarmfamily. A legend indicates that red bars represent 'Superfamilies'.

(iv) Descriptions Graphic Summary Alignments **Taxonomy**


Reports Lineage

4994 sequences selected ?


## Identifikované konzervované domény v rámci grafického súhrnu:



## Grafický súhrn – identifikované konzervované domény a skôre zrovnania:



Koniec grafického súhrnu, začiatok opisov a v nich prvý zásah:



## Koniec opisov, začiatok zrovnania a v nich prvý zásah:

<input type="checkbox"/> alpha-amylase [Glaciecola aerophilica NO21] >gi DAO5981.1  alpha_amylase [Glaciecola aerophilica NO21]	143	143	60%	4e-33	28%	<a href="#">ZP_1157552.1</a>
<input type="checkbox"/> hypothetical protein HMPREF9447_05299 [Bacteroides oleoiparus VIT_120581] >gi EKA87416.1  hypothetical protein HMPREF9447_05299 [Bacteroides oleoiparus VIT_120581]	145	145	63%	5e-33	28%	<a href="#">ZP_19884206.1</a>
<input type="checkbox"/> alpha-amylase [Abaformyces capreolatus H881]	142	142	50%	5e-33	27%	<a href="#">EGC45883.1</a>
<input type="checkbox"/> alpha-amylase [Sphaerotilus sphaerotilis japonicus VS5275] >gi EEB05074.1  alpha_amylase [Sphaerotilus sphaerotilis japonicus VS5275]	142	142	60%	5e-33	28%	<a href="#">XP_00211783.1</a>
<input type="checkbox"/> hypothetical protein AN3402_2 [Aspergillus nidulans FOBSC] >gi AAF17100.1 AF202824_1  alpha_amylase [Emeritaella fuliginea] >gi EA453370.1  hypothetical protein AN3402_2 [Aspergillus nidulans FOBSC A41] >gi CBF82779.1 TPA_Alpha-amylasePutative uncharacterized	143	200	65%	5e-33	33%	<a href="#">XP_001009_1</a>
<input type="checkbox"/> alpha-amylase putative [Aspergillus fumigatus AT1531]	143	143	57%	6e-33	27%	<a href="#">EGC53738.1</a>
<input type="checkbox"/> alpha-amylase precursor [Kordia alpidea OTI-1] >gi EDP96101.1  alpha_amylase [Sphaerotilus sphaerotilis japonicus VS5275]	142	142	64%	6e-33	28%	<a href="#">ZP_0210472.1</a>
<input type="checkbox"/> hypothetical protein BCIG_07832 [Botryotinia fuckeliana B05_101] >gi CDC49751.1  glycoside hydrolase family 13 protein [Botryotinia fuckeliana]	142	142	67%	6e-33	28%	<a href="#">XP_01553411.1</a>
<input type="checkbox"/> alpha-amylase [Aspergillus fumigatus AF293] >gi EAU07170.1  alpha_amylase putative [Aspergillus fumigatus AF293]	143	143	57%	7e-33	27%	<a href="#">XP_149208.1</a>
<input type="checkbox"/> hypothetical protein QXYTRI_05938 [Oxynota inflata] >gi EY78993.1  hypothetical protein QXYTRI_01378 [Oxynota inflata]	142	142	56%	7e-33	29%	<a href="#">EYJ78993.1</a>

### Alignments

Download ▾ GenPept Graphics

RecName: Full=Cyclomaltodextrin glucanotransferase; AltName: Full=Cyclodextrin-glycosyltransferase; Short=CGTase; Flags: Precursor Sequence ID: [sp|P30920.1|CDGT1\\_BACC](#) Length: 718 Number of Matches: 1  
► See 1 more title(s)

Range 1: 1 to 718	GenPept	Graphics	▼ Next Match	▲ Previous Match	Related Information
Score	Expect	Method	Identities	Positives	Gaps
1465 bits(3793) 0.0	Compositional matrix adjust.	718/718(100%) 0/718(0%)	718/718(100%) 0/718(0%)	718/718(100%) 0/718(0%)	
Query 1	MFQMAKRALPLSTTLTLLGLAGSALEPLPASAVYADPDTAVTNKQSFSTID/IYQVETDREL	60			
Sbjct 1	MFQMAKRALPLSTTLTLLGLAGSALEPLPASAVYADPDTAVTNKQSFSTID/IYQVETDREL	60			
Query 41	DGNSPNNPTGAAAYDATCSNLKLYCGDWNQGLINKINNDNYPSDLGVTLALWISQPVENIFAT	120			
Sbjct 41	DGNSPNNPTGAAAYDATCSNLKLYCGDWNQGLINKINNDNYPSDLGVTLALWISQPVENIFAT	120			
Query 121	INYSGVINTAYGYNWARDFKKTINPFYFGTMADPQNLITTAHAMGIKKIVIDFAPNHTSFAME	180			
Sbjct 121	INYSGVINTAYGYNWARDFKKTINPFYFGTMADPQNLITTAHAMGIKKIVIDFAPNHTSFAME	180			
Query 181	TDTSPAENGHLYDINGTLVGGYTINDTNGYFHHRNGGSDFSLENGIYRNLYDLADFNHNAT	240			
Sbjct 181	TDTSPAENGHLYDINGTLVGGYTINDTNGYFHHRNGGSDFSLENGIYRNLYDLADFNHNAT	240			
Query 241	IDKYFKDAIKRLWLMGVGDIRDAVKOMPLGWQKJSMSS1IYAHKP/FTFGEWFGLSAASD	300			
Sbjct 241	IDKYFKDAIKRLWLMGVGDIRDAVKOMPLGWQKJSMSS1IYAHKP/FTFGEWFGLSAASD	300			
Query 301	ADNTDFANKSGMSLDDFRNSAVRNVRINTTSNMYALDSMINSTATDYNQNDQVTFIDN	360			
Sbjct 301	ADNTDFANKSGMSLDDFRNSAVRNVRINTTSNMYALDSMINSTATDYNQNDQVTFIDN	360			
Query 361	HDMDRPFKTSVAVNNRBRLEQALAPLTSLRSGVPAIYYGTEQYLITGNQDPDNRAAMPFSKSTT	420			
Sbjct 361	HDMDRPFKTSVAVNNRBRLEQALAPLTSLRSGVPAIYYGTEQYLITGNQDPDNRAAMPFSKSTT	420			
Query 421	AFNVISKLAPLKRNPAIAYGSTQQRWINNDUVVYERKPGKSVAVVA/NRNLSTSASITG	480			
Sbjct 421	AFNVISKLAPLKRNPAIAYGSTQQRWINNDUVVYERKPGKSVAVVA/NRNLSTSASITG	480			
Query 481	LSTSLSPTGSYSTDVLGGVLNLGNNTISTNG8ISINNPTLAAGATAVWQYTTAETTPFIGHVGPF	540			
Sbjct 481	LSTSLSPTGSYSTDVLGGVLNLGNNTISTNG8ISINNPTLAAGATAVWQYTTAETTPFIGHVGPF	540			
Query 541	MGKPGNVTIDGRGFGSTKGT/VFGTTA/TGAAITSWEDTQIKUTIP5VAAGNYAVKVA	600			
Sbjct 541	MGKPGNVTIDGRGFGSTKGT/VFGTTA/TGAAITSWEDTQIKUTIP5VAAGNYAVKVA	600			
Query 601	SGV/NSRAYNNPFIILTDQ/QTVRFVNNASTTLQGQNLYLTQN/AELGNNSTGSTAIGPAPN	660			
Sbjct 601	SGV/NSRAYNNPFIILTDQ/QTVRFVNNASTTLQGQNLYLTQN/AELGNNSTGSTAIGPAPN	660			
Query 661	QVIHQYQPTWYDVSVPAGHQOLEKFKEFKGONGSTIWE3GSNH1FTTPASGTAIVTVNNQ	718			
Sbjct 661	QVIHQYQPTWYDVSVPAGHQOLEKFKEFKGONGSTIWE3GSNH1FTTPASGTAIVTVNNQ	718			

Prvý zásah v zrovnaniach – zrovnanie query samej so sebou:

Alignments

Download ▾ GenPept Graphics

RecName: Full=Cyclomaltodextrin glucanotransferase; AltName: Full=Cyclodextrin-glycosyltransferase; Short=CGTase; Flags: Precursor Sequence ID: [sp|P30920.1|CDGT1\\_BACC](#) Length: 718 Number of Matches: 1  
► See 1 more title(s)

Range 1: 1 to 718	GenPept	Graphics	▼ Next Match	▲ Previous Match	
Score	Expect	Method	Identities	Positives	Gaps
1465 bits(3793) 0.0	Compositional matrix adjust.	718/718(100%) 0/718(0%)	718/718(100%) 0/718(0%)	718/718(100%) 0/718(0%)	
Query 1	MFQMAKRALPLSTTLTLLGLAGSALEPLPASAVYADPDTAVTNKQSFSTID/IYQVETDREL	60			
Sbjct 1	MFQMAKRALPLSTTLTLLGLAGSALEPLPASAVYADPDTAVTNKQSFSTID/IYQVETDREL	60			
Query 61	DGNSPNNPTGAAAYDATCSNLKLYCGDWNQGLINKINNDNYPSDLGVTLALWISQPVENIFAT	120			
Sbjct 61	DGNSPNNPTGAAAYDATCSNLKLYCGDWNQGLINKINNDNYPSDLGVTLALWISQPVENIFAT	120			
Query 121	INYSGVINTAYGYNWARDFKKTINPFYFGTMADPQNLITTAHAMGIKKIVIDFAPNHTSFAME	180			
Sbjct 121	INYSGVINTAYGYNWARDFKKTINPFYFGTMADPQNLITTAHAMGIKKIVIDFAPNHTSFAME	180			
Query 181	TDTSPAENGHLYDINGTLVGGYTINDTNGYFHHRNGGSDFSLENGIYRNLYDLADFNHNAT	240			
Sbjct 181	TDTSPAENGHLYDINGTLVGGYTINDTNGYFHHRNGGSDFSLENGIYRNLYDLADFNHNAT	240			
Query 241	IDKYFKDAIKRLWLMGVGDIRDAVKOMPLGWQKJSMSS1IYAHKP/FTFGEWFGLSAASD	300			
Sbjct 241	IDKYFKDAIKRLWLMGVGDIRDAVKOMPLGWQKJSMSS1IYAHKP/FTFGEWFGLSAASD	300			
Query 301	ADNTDFANKSGMSLDDFRNSAVRNVRINTTSNMYALDSMINSTATDYNQNDQVTFIDN	360			
Sbjct 301	ADNTDFANKSGMSLDDFRNSAVRNVRINTTSNMYALDSMINSTATDYNQNDQVTFIDN	360			
Query 361	HDMDRPFKTSVAVNNRBRLEQALAPLTSLRSGVPAIYYGTEQYLITGNQDPDNRAAMPFSKSTT	420			
Sbjct 361	HDMDRPFKTSVAVNNRBRLEQALAPLTSLRSGVPAIYYGTEQYLITGNQDPDNRAAMPFSKSTT	420			
Query 421	AFNVISKLAPLKRNPAIAYGSTQQRWINNDUVVYERKPGKSVAVVA/NRNLSTSASITG	480			
Sbjct 421	AFNVISKLAPLKRNPAIAYGSTQQRWINNDUVVYERKPGKSVAVVA/NRNLSTSASITG	480			
Query 481	LSTSLSPTGSYSTDVLGGVLNLGNNTISTNG8ISINNPTLAAGATAVWQYTTAETTPFIGHVGPF	540			
Sbjct 481	LSTSLSPTGSYSTDVLGGVLNLGNNTISTNG8ISINNPTLAAGATAVWQYTTAETTPFIGHVGPF	540			
Query 541	MGKPGNVTIDGRGFGSTKGT/VFGTTA/TGAAITSWEDTQIKUTIP5VAAGNYAVKVA	600			
Sbjct 541	MGKPGNVTIDGRGFGSTKGT/VFGTTA/TGAAITSWEDTQIKUTIP5VAAGNYAVKVA	600			
Query 601	SGV/NSRAYNNPFIILTDQ/QTVRFVNNASTTLQGQNLYLTQN/AELGNNSTGSTAIGPAPN	660			
Sbjct 601	SGV/NSRAYNNPFIILTDQ/QTVRFVNNASTTLQGQNLYLTQN/AELGNNSTGSTAIGPAPN	660			
Query 661	QVIHQYQPTWYDVSVPAGHQOLEKFKEFKGONGSTIWE3GSNH1FTTPASGTAIVTVNNQ	718			
Sbjct 661	QVIHQYQPTWYDVSVPAGHQOLEKFKEFKGONGSTIWE3GSNH1FTTPASGTAIVTVNNQ	718			

## Na porovnanie – n-tý zásah (vo všeobecnosti):

Range 1: 31 to 506	Score	Expect	Method	Identities	Positives	Gaps
	145 bits(366)	1e-33	Compositional matrix adjust.	136/507(27%)	233/507(45%)	60/507(11%)
Query 51	IYQVFTDRFLDGNPSNNPTGAAYDATCSNLKLYCGGDNQGLINKINDNYFSIDLGVITALWI	110				
Query 111	IYQVFTDRFLDGNPSNNPTGAAYDATCSNLKLYCGGDNQGLINKINDNYFSIDLGVITALWI	169				
Query 170	PAPNHTSPAMETDTSTAEENGRLYDINGTLVGGYT-DTNGYFHRRNGSDFE---SSLENGI	224				
Query 225	YKMLYDLADENNNATIDKYPDKAIIK-LWLIMGV/DGIRVDA/KH-----MPLGWQKSMS	278				
Query 279	SIYAHKKPVFTPEGEWFLGSAAASDADNTIDFANKSGM-SLLDFRNSAVERN/FRDNTSMMVAL	337				
Query 328	DSEMINSTATIDYNNQ/NDQ/VIFPDIHMORFKTSAV/MNRALQALAPLTLSRGVPAIYVTE	397				
Query 398	QYLTMNGDPDNRAHM---PFSKSTTAANVVISKLAPL-----KSNPAlAYGSTQQRNWNN	450				
Query 451	DVIVYERKPKSVAVI/VNRLSTSAI-----TGLTSISLPTGSYTDVILEGV/LNGN	501				
Query 502	NITSTNGSINNETLAAGATAV/WQTTA	528				
Sbjct 31	IYQVFTDRFLDGNPSNNPTGAAYDATCSNLKLYCGGDNQGLINKINDNYFSIDLGVITALWI	84				
Sbjct 85	SPUVKRNIDGGSNGYTPDGSAAYGYWMAQDIYEINPHFPGASGLTDSNALHNRMVLMVD	144				
Sbjct 145	VVNVNRMAYCCTNGGCGPG-----NSTVNGSSTTPFNSSESYHPCCEIDYNNRTSILDcwE	199				
Sbjct 200	GDEIVPLVLDLRTEDSDV/QSIFNSWISNLQTYNIDGLRIDSLQQSGSFFFF-GFWQ---	254				
Sbjct 255	---AAGGMVGMVEVNNGNPSPVCP----YQQAGMPGV/LNYPMFVYITNAPQTSSGMSQL	307				
Sbjct 308	AQG18AMQSDCSDTLLGSPLENQNPFRPPSQTNIDLTRAQMAIAFTMLQDGIPITYQE	367				
Sbjct 368	QHLSGSGVPLNEALNTSGYDSSSPLYWMITT/WQLRTLAIKQNGGF/TYKIQVPTIDS	427				
Sbjct 428	N-HIVTRAKGNSGYQINGVYTINWSAGASSTLSSSETGFAQASEFV---MDVLSCLYH-	482				
Sbjct 483	--TGSDGSSL-STMTGGLERVFTINATA	506				

## Blastovanie s jednotlivou doménou proteínu:

- záznam z databázy UniProt; doména E – región 615-718

**Display**

- Entry**
- Publications
- Feature viewer
- Feature table

Function  
 Names & Taxonomy  
 Subcellular location  
 Pathology & Biotech  
 PTM / Processing  
 Expression  
 Interaction  
 Structure  
 Family & Domains

**Family & Domains<sup>i</sup>**

Domains and Repeats		
Feature key	Position(s)	Description
Domain <sup>i</sup>	532 – 612	IPT/TIG
Domain <sup>i</sup>	613 – 718	CBM20 <span style="color: yellow;">PROSITE-ProRule annotation</span>

Region		
Feature key	Position(s)	Description
Region <sup>i</sup>	35 – 172	A1
Region <sup>i</sup>	134 – 135	Substrate binding
Region <sup>i</sup>	173 – 236	B
Region <sup>i</sup>	227 – 230	Substrate binding <span style="color: yellow;">By similarity</span>
Region <sup>i</sup>	237 – 440	A2
Region <sup>i</sup>	266 – 267	Substrate binding
Region <sup>i</sup>	441 – 528	C
Region <sup>i</sup>	529 – 614	D
Region <sup>i</sup>	615 – 718	E

Vloženie query pri neúplnej sekvencii – dve možnosti postupu:

- vloží sa len konkrétny úsek sekvencie (napr. región 615-718)

The screenshot shows the NCBI BLAST search interface. In the 'Enter Query Sequence' field, a partial sequence is entered: 'IQQKQVQVAPITLTLAALGQDQVPTFPAVAVTAAQDQV...' followed by several question marks. To the right of this field are 'From' and 'To' input boxes, both currently empty. Below the sequence input, there are fields for 'Job Title' and 'Align two or more sequences'. The 'Choose Search Set' section is expanded, showing options for 'Database' (Non-redundant protein sequences), 'Organism' (Optional), 'Exclude' (Optional), and 'Entrez Query' (Optional). The 'Program Selection' section shows 'blastp (protein-protein BLAST)' selected. At the bottom, a blue button labeled 'BLAST' is visible.

- alebo sa vloží celá sekvencia a vyznačia sa hranice („Query subrange“)

This screenshot shows the same NCBI BLAST interface as above, but with a different query input. The entire sequence 'IQQKQVQVAPITLTLAALGQDQVPTFPAVAVTAAQDQV...' is entered in the 'Enter Query Sequence' field. Above this input, the 'Query subrange' section is active, with 'From' set to '615' and 'To' set to '718'. The rest of the interface elements are identical to the first screenshot, including the 'Choose Search Set' and 'Program Selection' sections, and the 'BLAST' button at the bottom.

Detailný popis konkrétneho výsledku – n-tý zásah:

[Download](#) [GenPept Graphics](#)

alpha-amylase [Halomonas sp. KM-1]

Sequence ID: [ref|ZP\\_10778855.1|](#) Length: 587 Number of Matches: 1

Range 1: 485 to 583 [GenPept Graphics](#)

Score Expect Method Identities Positives Gaps

51.6 bits(122) 1e-05 Compositional matrix adjust. 32/104(31%) 52/104(50%) 9/104(8%)

Query	615	TGDQVTVRFVVNNASTTLLGQNLYLTGNVAELGNWSTGSTAIGPAFNQVIHQYPTWYYDVS	674
	++ V+V F N +T LGQ++Y+TG+ LGNWS	N YPTW +	
Sbjct	485	SDENSVTFTCANGTTELGQSVDVTGSNQALGNWSPAELKLEPVN-----YPTWSGTFN	539
Query	675	VPAGKQLEFKFFKKN----GSTITWESGSNHTFTTPASGTATVT	714
	+P +E+K K++ S + W+ G+N+ T +G+ T		
Sbjct	540	MPEANANIEWKCIRSETEPESMLEWQPGNNNLLETGQTGSTVST	583

Možno povedať, že blastovaná doména (úsek sekvencie 615-718), resp. jej potenciálny homológ, sa nachádza v  $\alpha$ -amyláze z *Halomonas* sp. KM-1 na C-konci proteínu, keďže korešpondujúce úseky sú 615-714 (takmer celý úsek) a 485-583 (dĺžka sekvencie „subject“ je 587 zvyškov).

proteín/enzým

zdroj proteínu/enzýmu (organizmus)

[Download](#) [GenPept Graphics](#)

alpha-amylase [Halomonas sp. KM-1]

prístupové číslo z príslušnej databázy

Sequence ID: [ref|ZP\\_10778855.1|](#) Length: 587 Number of Matches: 1

dĺžka proteínu/enzýmu (aminokyselinovej sekvencie)

Range 1: 485 to 583 [GenPept Graphics](#)

Score Expect Method Identities Positives Gaps

51.6 bits(122) 1e-05 Compositional matrix adjust. 32/104(31%) 52/104(50%) 9/104(8%)

Query	615	TGDQVTVRFVVNNASTTLLGQNLYLTGNVAELGNWSTGSTAIGPAFNQVIHQYPTWYYDVS	674
	++ V+V F N +T LGQ++Y+TG+ LGNWS	N YPTW +	
Sbjct	485	SDENSVTFTCANGTTELGQSVDVTGSNQALGNWSPAELKLEPVN-----YPTWSGTFN	539
Query	675	VPAGKQLEFKFFKKN----GSTITWESGSNHTFTTPASGTATVT	714
	+P +E+K K++ S + W+ G+N+ T +G+ T		
Sbjct	540	MPEANANIEWKCIRSETEPESMLEWQPGNNNLLETGQTGSTVST	583

charakteristika zrovnania

začiatok korešpondujúcich úsekov

koniec korešpondujúcich úsekov

## 6. PDB, modelovanie a porovnávanie štruktúr proteínov

Úvodná web-stránka databázy PDB – Protein Data Bank:

<http://www.rcsb.org/>

The screenshot shows the main interface of the RCSB PDB website. At the top, there's a navigation bar with links for Deposit, Search, Visualize, Analyze, Download, Learn, and More, along with a MyPDB account dropdown. Below the header is the RCSB PDB logo and a search bar with a placeholder 'Enter search term(s)'. A world map graphic is visible in the background.

**Welcome:** A Structural View of Biology. This section highlights the RCSB PDB's role in curating and annotating PDB data, its focus on molecular biology, structural biology, and computational biology, and its COVID-19 resources. It features a 3D visualization of the Capsaicin Receptor TRPV1.

**Latest Entries:** Shows a 3D structure of human ATG9A in LMNG micelles (entry code 7JLQ).

**Features & Highlights:** Includes sections on Building Advanced Searches, Sequence Alignments in Search Results, and Customizing Tabular Reports of PDB Data.

**News:** Service Disruptions November 3-10, American Public Health Association Film Festival, and PDB Turns 49.

**Publications:** News about the anniversary of the PDB's 1971 announcement and Irving Geis' birthday.

At the bottom, there's a footer with links for PDB at a Glance, statistics (170383 Structures, 49693 Human Sequences, 12430 Nucleic Acid Containing Structures), and more links for About Us, Help, RCSB Partners, and wwPDB Partners. The footer also mentions funding from the National Science Foundation, US Department of Energy, and National Cancer Institute.

Protein Data Bank (PDB) je databáza, v ktorej sú uchovávané vyriešené terciárne štruktúry najmä proteínov, ale aj ďalších veľkých biologických molekúl (DNA a RNA). PDB vznikla v roku 1971 v rámci Brookhaven National Laboratory (USA) ako zdroj digitálnych dát s otvoreným prístupom v rámci celej biológie a medicíny. Do dnešnej internetovej podoby prešla

v roku 2003 ako tzv. „Worldwide PDB“, ktorá spravuje celý archív PDB a zabezpečuje, že celá databáza je voľne a verejne dostupná pre všetkých užívateľov bez obmedzeia. V súčasnosti predstavuje jeden z hlavných globálnych zdrojov experimentálnych dát, ktoré sú nevyhnutné pre vedecké bádanie a objavy.

Vyriešiť terciárnu štruktúru proteínu znamená vyriešiť – t.j. poznať – koordináty v priestore (x, y, z) – t.j. pozíciu – pre všetky atómy, ktoré tvoria molekulu proteínu. Najdôležitejšie sú 4 atómy – dusík (z -NH<sub>2</sub> skupiny), alfa-uhlík a karboxylový uhlík s kyslíkom (z -COOH skupiny), ktoré tvoria kostru polypeptidového reťazca. Samozrejme, pre presné určenie terciárnej štruktúry proteínu je potrebné určiť koordináty aj ostatných atómov z postranných reťazcov všetkých aminokyselinových zvyškov. Presnosť vyriešenia štruktúry proteínu – tzv. rozlíšenie – sa udáva v jednotkách „Å“ (10<sup>-10</sup> m). Veľmi dobré (detailné) štruktúry proteínov sú vyriešené pri rozlíšení 1-2 Å; pri rozlíšení pod 1 Å sa stávajú „viditeľné“ aj atómy vodíka, ktoré sú príliš malé a ich pozícia sa pri horšom rozlíšení (t.j. vyššej hodnote „Å“) nedá určiť. Treba si uvedomiť, že štruktúra proteínu je určená (vyriešená) tým lepšie (presnejšie), čím je hodnota rozlíšenia udaná v „Å“ nižšia; samotné rozlíšenie je tým väčšie, čím je hodnota „Å“ nižšia.


<b>ATOM</b>	<b>1</b>	<b>N</b>	<b>ALA</b>	<b>A</b>	<b>1</b>	<b>-8.065</b>	<b>17.989</b>	<b>-10.906</b>	<b>1.00</b>	<b>0.00</b>	<b>N</b>
<b>ATOM</b>	<b>2</b>	<b>CA</b>	<b>ALA</b>	<b>A</b>	<b>1</b>	<b>-7.235</b>	<b>16.799</b>	<b>-11.163</b>	<b>1.00</b>	<b>0.00</b>	<b>C</b>
<b>ATOM</b>	<b>3</b>	<b>C</b>	<b>ALA</b>	<b>A</b>	<b>1</b>	<b>-8.117</b>	<b>15.784</b>	<b>-10.473</b>	<b>1.00</b>	<b>0.00</b>	<b>C</b>
<b>ATOM</b>	<b>4</b>	<b>O</b>	<b>ALA</b>	<b>A</b>	<b>1</b>	<b>-8.999</b>	<b>16.398</b>	<b>-9.862</b>	<b>1.00</b>	<b>0.00</b>	<b>O</b>
<b>ATOM</b>	<b>5</b>	<b>CB</b>	<b>ALA</b>	<b>A</b>	<b>1</b>	<b>-6.004</b>	<b>16.975</b>	<b>-10.304</b>	<b>1.00</b>	<b>0.00</b>	<b>C</b>

**Obr. 6.1.** Ukážka zápisu koordinát pre aminokyselinu Ala1 v reťazci „A“ α-amylázy z *Aspergillus oryzae*, ktoré sú v PDB uložené pod PDB kódom: 2TAA. Zápis pre alanín je tvorený 5 riadkami: N, Ca (CA), C, O a Cβ (CB).

Terciárne štruktúry sú v PDB uložené v súboroch, ktoré majú pridelené tzv. PDB kódy (podobne ako prístupové číslo v sekvenčných databázach; „Accession No.“). Minimálny počet riadkov v PDB súbore pre jednu aminokyselinu je 4, t.j. štyri atómy: N, Ca a C(O) uvedené vyššie (obr. 6.1), tvoriace kostru reťazca; to však platí pre glycín, ktorý nemá postranný reťazec. To znamená, že PDB súbory sú vo všeobecnosti veľmi veľké, keďže napr. priemerný proteín s 500 aminokyselinovými zvyškami musí obsahovať

viac ako 2 000 riadkov „ATOM“ s koordinátami; 2 000 riadkov by mal súbor vtedy, keby bol proteín tvorený iba samými glycínmí (t.j. iba 4 riadky na jeden zvyšok). Pritom v každom PDB súbore sa nachádza aj mnoho poznámok („REMARKS“); a väčšina štruktúr obsahuje na jednu molekulu proteínu niekoľko stoviek molekúl vody (sú vyriešené ako pozície atómu kyslíka z molekuly H<sub>2</sub>O).

Detailedy k terciárnej štruktúre proteínov, k organizácii PDB súboru proteínu v PDB, ako aj k teoretickým základom predikcií sekundárnej a terciárnej štruktúry proteínov sú uvedené v učebnom texte „Proteínový dizajn“, ktorý je dostupný online na adrese Univerzity sv. Cyrila a Metoda v Trnave: [http://fpv.ucm.sk/images/ucebne\\_texty/Proteinovy\\_dizajn.pdf](http://fpv.ucm.sk/images/ucebne_texty/Proteinovy_dizajn.pdf).



**Obr. 6.2.** Porovnanie nárastu dát v priebehu troch posledných rokov v sekvenčnej databáze GenBank a v štruktúrnej databáze PDB. Dochádza k neustále narastajúcemu rozdielu medzi poznaním sekvenčních dát a poznaním štruktúr.

Možnosti predikcie terciárnych štruktúr proteínov poskytujú potenciál spomalit nepriaznivý trend enormného nárastu sekvenčných dát oproti omnoho pomalšiemu nárastu štruktúrnych dát v PDB (obr. 6.2).

V nasledujúcej časti budú predstavené, resp. popísané jednotlivé praktické kroky pri získaní vhodného modelu terciárnej štruktúry proteínu, interpretáciu výsledkov modelovania, ako aj následného porovnania štruktúry modelu s reálnou štruktúrou proteínu, ktorý je k nemu homologický, t.j. ktorý by mohol, ale aj nemusel byť použitý pri modelovaní ako jeho templát.

Pre predikciu štruktúry proteínov existujú rôzne servery; jedným z nich je server Phyre2, kde je možné získať model tzv. induktívou metódou rozpoznania štruktúry („fold recognition“). Princípom je, že program vyhľadáva v PDB štruktúry homologických proteínov, ktoré majú čo najvyšší stupeň sekvenčnej podobnosti s proteínom, o predikciu štruktúry ktorého je záujem. Tieto homologické proteíny slúžia ako štruktúrne templáty (vzory). To znamená, že výsledkom – v prípade, že existuje dostatok experimentálne určených terciárnych štruktúr homologických proteínov – je teoreticky toľko modelov, koľko templátov je v PDB identifikovaných.

Phyre2 spravidla poskytuje maximálne 20 modelov; v prípade väčšieho počtu identifikovaných vhodných templátov program poskytne získané dáta bez štruktúrnych koordinát modelov.

Pre využitie a správnu interpretáciu výsledkov je dôležité vziať do úvahy niekoľko nasledujúcich poznámok:

- (i) v stĺpci hned vedľa poradového čísla („Template“) sú zapísané PDB kódy použitých templátov, napr. „d1cyga2“ a „d1kula“ znamená, že PDB kódy sú „1CYG“, resp. „1KUL“;
- (ii) stĺpec „Alignment Coverage“ je veľmi dôležitý, pretože udáva, aká časť sekvencie bola modelovaná; čím bližšie k 100%, tým lepšie;
- (iii) cez stĺpec „3D Model“ je možné získať koordináty (t.j. terciárnu štrukrúru) modelu sekvencie na danom prekryve s templátom (alignment coverage); je dôležité si štruktúru vhodne uložiť;
- (iv) stĺpec „Confidence“ udáva pravdepodobnosť (0-100%), že templát a modelovaná sekvencia sú homológy; neudáva presnosť modelu;
- (v) predposledný stĺpec „% i.d.“ znamená sekvenčnú identitu v rámci daného sekvenčného prekryvu; „% i.d.“ a „Alignment Coverage“ sú spolu najdôležitejšími hodnotami pre výber vhodného modelu;
- (vi) posledný stĺpec obsahuje stručný popis templátu.

Úvodná web-stránka serveru Phyre2:

<http://www.sbg.bio.ic.ac.uk/~phyre2/>

The screenshot shows the Phyre2 web interface. At the top, there are links for "Standard Mode" and "Login" for job management, and a "Fetch" button. Below the header is the Phyre2 logo and the text "Protein Homology/analogy Recognition Engine V 2.0". To the right, there's a "Subscribe to Phyre at Google Groups" section with a "Subscribe" button and a "Follow @Phyre2server" link. A navigation bar below the logo includes icons for search, help, and file operations. A "Position opening" section invites users to contact Prof. Michael Sternberg. Below this, under "Other Resources", are links to "Missense3D" and "PhyreRisk". A horizontal line separates these from the main search form. The search form itself has fields for "E-mail Address" and "Optional Job description". It includes a large text area for "Amino Acid Sequence" with a "Or try the sequence finder" link. Under "Modelling Mode", there are radio buttons for "Normal" (selected) and "Intensive". Below this is a checkbox for "Please tick as appropriate." followed by "NOT for Profit", "FOR Profit (Commercial)", and "Other". At the bottom of the form are "Phyre Search" and "Reset" buttons. A small note at the bottom states "3806023 submissions since Feb 14 2011". Below the form, a horizontal line contains the text "Phyre is now FREE for commercial users!", a note about free use for publications, and citation information: "Please cite: The Phyre2 web portal for protein modeling, prediction and analysis Kelley LA et al. Nature Protocols 10, 845-858 (2015) [paper] [Citation link]". Logos for Elixir United Kingdom, Imperial College London, and BBSRC Genome3D are displayed at the bottom.

Na začiatku je potrebné vložiť aminokyselinovú sekvenciu proteínu (alebo jej časť), o predikciu terciárnej štruktúry ktorého je záujem. Je výhodné si túto predikciu nejako vhodne nazvať („Job description“) – napr. možno použiť názov proteínu, prístupové číslo z databázy GenBank alebo UniProt, prípadne rozsah aminokyselinovej sekvencie pri predikcii jej časti, apod. Pre bežné prípady úplne postačuje normálny spôsob modelovania („modelling mode“: „Normal“); t.j. nie „Intensive“.

Ako vidno nižšie, výsledky, ktoré poskytuje server Phyre2, sú v podstate veľmi rozsiahle. V tomto konkrétnom prípade bola modelovaná C-terminálna časť proteínu genetonin-1 (prístupové číslo z databázy UniProt: O95210) v úseku Gly260-His358. Táto časť korešponduje so škrob-viažucou doménou z rodiny CBM20 („carbohydrate-binding module family 20“) mikrobiálnych amylolytických enzýmov.

### Výsledky modelovania zo serveru Phyre2:

**Phyre Home** **Retrieve Phyre Job Id** **Fetch**

**Phyre<sup>2</sup>**

Email: Stefan.Janecek@svbcs.slu Description: Genethonin\_1\_UniProt\_O95210\_G260\_H258 Date: Tue Oct 27 13:55:09 GMT 2020 Unique Job ID: 28d699f81c8a925c Sequence: GSQQVSVRFQ ... [Download FASTA](#) Job Type: normal Job Expiry: 27 days Renew for 30 days

[Download zip of all results](#)

**Summary**

**Top model**

Model (left) based on template [d1cygq2](#) [Top template information](#)

**Fold:**Prealbumin-like **Superfamily:**Starch-binding domain-like **Family:**Starch-binding domain

Confidence and coverage

Confidence: 100.0% Coverage: 95%

94 residues ( 95% of your sequence) have been modelled with 100.0% confidence by the single highest scoring template.

[3D viewing](#) [Interactive 3D view in JSmol](#)

For other options to view your downloaded structure offline see the [FAQ](#)

Image coloured by rainbow N → C terminus  
Model dimensions (Å): X:32.036 Y:35.314 Z:42.900

**Sequence analysis**

[View PSI-Blast Pseudo-Multiple Sequence Alignment](#) [Download FASTA version](#)

**Secondary structure and disorder prediction** [Show]

**Domain analysis** [Show]

**Detailed template information** [Hide]

[Run Investigator](#)

#	Template	Alignment Coverage	3D Model	Confidence	% I.D.	Template Information
1	<a href="#">d1cygq2</a>	<a href="#">Alignment</a>		100.0	31	<b>Fold:</b> Prealbumin-like <b>Superfamily:</b> Starch-binding domain-like <b>Family:</b> Starch-binding domain <a href="#">Phyre<sup>2</sup> Run Investigator</a>
2	<a href="#">d1kula</a>	<a href="#">Alignment</a>		100.0	30	<b>Fold:</b> Prealbumin-like <b>Superfamily:</b> Starch-binding domain-like <b>Family:</b> Starch-binding domain <a href="#">Phyre<sup>2</sup> Run Investigator</a>
3	<a href="#">d1cqta2</a>	<a href="#">Alignment</a>		100.0	31	<b>Fold:</b> Prealbumin-like <b>Superfamily:</b> Starch-binding domain-like <b>Family:</b> Starch-binding domain <a href="#">Phyre<sup>2</sup> Run Investigator</a>
4	<a href="#">d1ghoq2</a>	<a href="#">Alignment</a>		99.9	24	<b>Fold:</b> Prealbumin-like <b>Superfamily:</b> Starch-binding domain-like <b>Family:</b> Starch-binding domain <a href="#">Phyre<sup>2</sup> Run Investigator</a>
5	<a href="#">d3bmva2</a>	<a href="#">Alignment</a>		99.9	30	<b>Fold:</b> Prealbumin-like <b>Superfamily:</b> Starch-binding domain-like <b>Family:</b> Starch-binding domain <a href="#">Phyre<sup>2</sup> Run Investigator</a>
6	<a href="#">c0fmaA</a>	<a href="#">Alignment</a>		99.9	29	<b>PDB header:</b> hydrolase <b>Chain:</b> A: <b>PDB Molecule:</b> glucoamylase; <b>PDB Title:</b> crystal structure of penicillium oxalicum glucoamylase <a href="#">Phyre<sup>2</sup> Run Investigator</a>

## Výsledky modelovania zo serveru Phyre2 (pokračovanie):

7	d1cda2	Alignment		99.9	32	Superfamily: Starch-binding domain-like Family: Starch-binding domain <a href="#">Phyre2</a> Run Investigator
8	d1pma2	Alignment		99.9	31	Fold: Prealbumin-like Superfamily: Starch-binding domain-like Family: Starch-binding domain <a href="#">Phyre2</a> Run Investigator
9	c2ymA	Alignment		99.9	29	PDB header: hydrolase Chain: A: PDB Molecule: glucoamylase; PDBTitle: glycoside hydrolase family 15 glucoamylase from hypocrea jecorina <a href="#">Phyre2</a> Run Investigator
10	c6fhwB	Alignment		99.9	29	PDB header: hydrolase Chain: B: PDB Molecule: glucoamylase p; PDBTitle: structure of hormonis resinae glucoamylase <a href="#">Phyre2</a> Run Investigator
11	d1vema1	Alignment		99.9	19	Fold: Prealbumin-like Superfamily: Starch-binding domain-like Family: Starch-binding domain <a href="#">Phyre2</a> Run Investigator
12	c2z0hB	Alignment		99.9	21	PDB header: hydrolase Chain: B: PDB Molecule: putative glycerophosphodiester phosphodiesterase 5; PDBTitle: crystal structure of cbm20 domain of human putative2 glycerophosphodiester phosphodiesterase 5 (Kiaa1434) <a href="#">Phyre2</a> Run Investigator
13	c1j0y0	Alignment		99.7	22	Chain: D: PDB Molecule: beta-amylase; PDBTitle: beta-amylase from bacillus cereus var. mycoides in complex with 2 glucose <a href="#">Phyre2</a> Run Investigator
14	c1rkA	Alignment		99.2	26	PDB header: hydrolase Chain: A: PDB Molecule: laforin; PDBTitle: structure of a product bound phosphatase <a href="#">Phyre2</a> Run Investigator
15	c1oyA	Alignment		98.8	29	PDB header: glycosyltransferase Chain: A: PDB Molecule: cyclodextrin glucanotransferase; PDBTitle: cyclodextrin glucanotransferase (e.c.2.4.1.19) (cgtae) <a href="#">Phyre2</a> Run Investigator
16	c1ghoA	Alignment		98.7	25	PDB header: hydrolase Chain: A: PDB Molecule: alpha-amylase; PDBTitle: five-domain alpha-amylase from bacillus stearothermophilus,2 maltose/acearbose complex <a href="#">Phyre2</a> Run Investigator
17	c3nmeA	Alignment		98.5	24	PDB header: hydrolase Chain: A: PDB Molecule: ex4 glucan phosphatase; PDBTitle: structure of a plant phosphatase <a href="#">Phyre2</a> Run Investigator
18	c3bmwA	Alignment		98.3	28	PDB header: transferase Chain: A: PDB Molecule: cyclomaltoextrin glucanotransferase; PDBTitle: cyclodextrin glycosyl transferase from thermoerobacterium2 thermosulfurigenes em1 mutant s77p complexed with a maltoheptaose3 inhibitor <a href="#">Phyre2</a> Run Investigator
19	c4jcmA	Alignment		98.3	28	PDB header: transferase Chain: A: PDB Molecule: cyclodextrin glucanotransferase; PDBTitle: crystal structure of gamma-cgtase from alkaliphilic bacillus clarkii2 at 1.65 angstrom resolution <a href="#">Phyre2</a> Run Investigator
20	d2f15a1	Alignment		98.1	21	Fold: Immunoglobulin-like beta-sandwich Superfamily: E set domains Family: AMPK-beta glycogen binding domain-like <a href="#">Phyre2</a> Run Investigator
21	c4jcIA	Alignment	not modelled	98.1	27	PDB header: transferase Chain: A: PDB Molecule: cyclomaltoextrin glucanotransferase; PDBTitle: crystal structure of alpha-cgt from paenibacillus macerans at 1.72 angstrom resolution <a href="#">Phyre2</a> Run Investigator
22	c1tcmB	Alignment	not modelled	98.0	26	PDB header: glycosyltransferase Chain: B: PDB Molecule: cyclodextrin glycosyltransferase; PDBTitle: cyclodextrin glycosyltransferase w616a mutant from bacillus2 circulans strain 251 <a href="#">Phyre2</a> Run Investigator
23	c2alvB	Alignment	not modelled	97.7	23	PDB header: transferase/protein binding Chain: B: PDB Molecule: protein sfp2; PDBTitle: crystal structure of the heterotrimer core of the s. cerevisiae ampk2 homolog snf1 <a href="#">Phyre2</a> Run Investigator
24	d2alvb1	Alignment	not modelled	97.7	18	Fold: Immunoglobulin-like beta-sandwich Superfamily: E set domains Family: AMPK-beta glycogen binding domain-like <a href="#">Phyre2</a> Run Investigator
25	d1z0na1	Alignment	not modelled	97.6	13	Fold: Immunoglobulin-like beta-sandwich Superfamily: E set domains Family: AMPK-beta glycogen binding domain-like <a href="#">Phyre2</a> Run Investigator
26	d1z0mb1	Alignment	not modelled	97.5	18	Fold: Immunoglobulin-like beta-sandwich Superfamily: E set domains Family: AMPK-beta glycogen binding domain-like <a href="#">Phyre2</a> Run Investigator
27	c4beyC	Alignment	not modelled	97.1	16	PDB header: transferase Chain: C: PDB Molecule: 1,4-alpha-glucan-branched enzyme; PDBTitle: crystal structure of human glycogen branching enzyme (gbe1) <a href="#">Phyre2</a> Run Investigator

## Výsledky modelovania zo serveru Phyre2 (pokračovanie, prerušenie: 27→46):

46	<a href="#">c2wskA</a>	Alignment	not modelled	90.5	8	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:glycogen debranching enzyme; <b>PDBTitle:</b> crystal structure of glycogen debranching enzyme glgx from2 escherichia coli k-12
47	<a href="#">c1bf2A</a>	Alignment	not modelled	90.4	15	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:isoamylase; <b>PDBTitle:</b> structure of pseudomonas isoamylase
48	<a href="#">d2bhua1</a>	Alignment	not modelled	89.9	21	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> E set domains <b>Family:</b> E-set domains of sugar-utilizing enzymes
49	<a href="#">c4fhbB</a>	Alignment	not modelled	88.7	22	<b>PDB header:</b> carbohydrate-binding protein <b>Chain:</b> B: PDB Molecule:outer membrane protein susc; <b>PDBTitle:</b> crystal structure of susc from bacteroides thetaiotaomicron with2 maltotetraose
50	<a href="#">c2C3wb</a>	Alignment	not modelled	87.4	19	<b>PDB header:</b> sugar binding protein <b>Chain:</b> B: PDB Molecule:alpha-amylase g-6; <b>PDBTitle:</b> structure of cbm25 from bacillus halodurans amylase in complex with2 maltotetraose
51	<a href="#">c1ea9D</a>	Alignment	not modelled	87.3	17	<b>PDB header:</b> hydrolase <b>Chain:</b> D: PDB Molecule:cyclomaltodextrinase; <b>PDBTitle:</b> cyclomaltodextrinase
52	<a href="#">c3wdjA</a>	Alignment	not modelled	86.5	15	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:type i pullulanase; <b>PDBTitle:</b> crystal structure of pullulanase complexed with maltotetraose from2 anoxybacillus sp. lm18-11
53	<a href="#">d1j0ha1</a>	Alignment	not modelled	85.9	15	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> E set domains <b>Family:</b> E-set domains of sugar-utilizing enzymes
54	<a href="#">c4femA</a>	Alignment	not modelled	85.0	21	<b>PDB header:</b> carbohydrate-binding protein <b>Chain:</b> A: PDB Molecule:outer membrane protein susc; <b>PDBTitle:</b> structure of susc with alpha-cyclodextrin
55	<a href="#">c5wvtA</a>	Alignment	not modelled	84.9	11	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:pullulanase; <b>PDBTitle:</b> catalytic mechanism, cyclodextrin inhibition, and allosteric2 regulation of paenibacillus barengoltzi pullulanase

## Výsledky modelovania zo serveru Phyre2 (pokračovanie, prerušenie: 55→61):

61	<a href="#">c1oyIA</a>	Alignment	not modelled	81.1	19	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:maltogenic amylase; <b>PDBTitle:</b> thermus maltogenic amylase in complex with beta-cd
62	<a href="#">c4fe9A</a>	Alignment	not modelled	78.9	13	<b>PDB header:</b> carbohydrate-binding protein <b>Chain:</b> A: PDB Molecule:outer membrane protein susc; <b>PDBTitle:</b> crystal structure of susc from bacteroides thetaiotaomicron
63	<a href="#">d1eh9a1</a>	Alignment	not modelled	76.6	14	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> E set domains <b>Family:</b> E-set domains of sugar-utilizing enzymes
64	<a href="#">c1jbA</a>	Alignment	not modelled	76.0	12	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:neopullulanase; <b>PDBTitle:</b> complex of alpha-amylase ii (tva ii) from thermoactinomyces vulgaris r-47 with maltotetraose based on a crystal soaked with maltohexaose.
65	<a href="#">c2lsaA</a>	Alignment	not modelled	70.7	13	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:beta/alpha-amylase; <b>PDBTitle:</b> solution structure of the cbm25-1 of beta/alpha-amylase from2 paenibacillus polymyxa
66	<a href="#">c3faxA</a>	Alignment	not modelled	70.2	12	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:erythrocyte binding protein; <b>PDBTitle:</b> the crystal structure of gbs pullulanase sap in complex with2 maltotetraose
67	<a href="#">c2by0A</a>	Alignment	not modelled	68.3	21	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:maltooligosyltrehalose trehalohydrolyase; <b>PDBTitle:</b> is radiation damage dependent on the dose-rate used during2 macromolecular crystallography data collection
68	<a href="#">c6ne9B</a>	Alignment	not modelled	64.3	12	<b>PDB header:</b> hydrolase <b>Chain:</b> B: PDB Molecule:isoamylase protein; <b>PDBTitle:</b> bacteroides intestinalis acetyl xylan esterase (bacint_01039)
69	<a href="#">c5t7aA</a>	Alignment	not modelled	63.7	16	<b>PDB header:</b> sugar binding protein <b>Chain:</b> A: PDB Molecule:h0236 protein; <b>PDBTitle:</b> crystal structure of br derivative hbcmb56
70	<a href="#">c5ot1A</a>	Alignment	not modelled	62.5	19	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:pullulanase type ii, gh3 family; <b>PDBTitle:</b> the type iii pullulanase from thermococcus kodakarensis
71	<a href="#">c1ehsA</a>	Alignment	not modelled	61.8	12	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:glycosyltrehalose trehalohydrolyase; <b>PDBTitle:</b> crystal structure of glycosyltrehalose trehalohydrolyase from2 sulfobolbus softarticus
72	<a href="#">c2d0gA</a>	Alignment	not modelled	59.9	12	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:alpha-amylase i; <b>PDBTitle:</b> crystal structure of thermoactinomyces vulgaris r-47 alpha-amylase 12 (tva) mutant d356n/e396q complexed with p5, a pullulan model3 oligosaccharide
73	<a href="#">d1ea9c1</a>	Alignment	not modelled	54.9	17	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> E set domains <b>Family:</b> E-set domains of sugar-utilizing enzymes
74	<a href="#">c3c8dA</a>	Alignment	not modelled	44.0	10	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:centerochelin esterase; <b>PDBTitle:</b> crystal structure of the enterobactin esterase fes from2 shigella flexneri in the presence of 2,3-di-hydroxy-n-3 benzoyl-glycine
75	<a href="#">d2fhfa1</a>	Alignment	not modelled	42.1	14	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> set domains <b>Family:</b> E-set domains of sugar-utilizing enzymes
76	<a href="#">d3c8da1</a>	Alignment	not modelled	35.2	19	<b>Fold:</b> immunoglobulin-like beta-sandwich <b>Superfamily:</b> E set domains <b>Family:</b> Enterochelin esterase N-terminal domain-like
77	<a href="#">c2ya1A</a>	Alignment	not modelled	34.3	13	<b>PDB header:</b> hydrolase <b>Chain:</b> A: PDB Molecule:putative alkaline amylopullulanase; <b>PDBTitle:</b> product complex of a multi-modular glycogen-degrading pneumococcal2 virulence factor spa
78	<a href="#">c2jnza</a>	Alignment	not modelled	29.4	18	<b>PDB header:</b> allergen <b>Chain:</b> A: PDB Molecule:phl p 3 allergen; <b>PDBTitle:</b> solution structure of phl p 3, a major allergen from2 timothy grass pollen
79	<a href="#">c6mouB</a>	Alignment	not modelled	26.3	22	<b>PDB header:</b> hydrolase <b>Chain:</b> B: PDB Molecule:isoamylase n-terminal domain protein; <b>PDBTitle:</b> bacteroides intestinalis feruloyl esterase, bacint_01033
80	<a href="#">d1zr1A</a>	Alignment	not modelled	22.6	12	<b>Fold:</b> gamma-Crystallin-like <b>Superfamily:</b> gamma-Crystallin-like <b>Family:</b> Crystallins/Ca-binding development proteins

## Výsledky modelovania zo serveru Phyre2 (pokračovanie; dokončenie):

Automated 3DLigandSite submission is temporarily suspended due to server load. However you may submit models directly to 3DLigandSite [HERE](#)

[Generate superposition of selected models](#)

Binding site prediction

Phyre is now FREE for commercial users!

All images and data generated by Phyre2 are free to use in any publication with acknowledgement

Please cite: The Phyre2 web portal for protein modeling, prediction and analysis.  
Kelley LA et al., *Nature Protocols* 10, 845-858 (2015) [[pdf](#)] [[Citation link](#)]

If you use the binding site predictions from 3DLigandSite, please also cite:  
3DLigandSite: predicting ligand-binding sites using similar structures.  
Wass MN, Kelley LA and Sternberg MJ *Nucleic Acids Research* 38, W469-73 (2010) [[PubMed](#)]

© Structural Bioinformatics Group  
Imperial College London  
Lawrence Kelley, Michael Sternberg  
Disclaimer  
[Terms and Conditions](#)

Component software  
Template detection: [Biased 1.51](#)  
Secondary structure prediction: [Biased 2.5](#)  
Disorder prediction: [Biased 2.4](#)  
Transmembrane prediction: [Memsat\\_SVM](#)  
Multi-template modelling and ab initio: [Pompe 1.0](#)

Imperial College London

Výsledky modelovania ostávajú na serveri Phyre2 dostupné približne 1 mesiac; v každom prípade je najlepšie si ich stiahnuť zo servera a uložiť vo vlastnom počítači – na to je možné využiť tlačítka na titulnej strane hned pod hlavičkou: „Download zip of all results“. Je veľkou výhodou, že výsledky po rozbalení sú k dizpozícii v úplne totožnej forme aj vizuálnom spracovaní tak, ako boli v origináli na serveri.

## Výsledky modelovania zo serveru Phyre2:


- zobrazené sú rozkliknuté výsledky zrovnania sekvencie modelovaného proteínu („Query Sequence“) a sekvencie proteínu, ktorého štruktúra bola použitá ako templát („Template sequence“) v rámci daného sekvenčného prekryvu („Alignment Coverage“);
- toto zrovnanie je založené na štruktúre („structure-based alignment“);
- konkrétny templát: „d1cgta2“ (1CGT); úsek sekvencie: Gly582-Trp683.

[Return to main results](#) [Retrieve Phyre Job Id](#) [Fetch](#)

**Phyre<sup>2</sup>**

Job Description	Genethonin_1_UniProt_O95210_G260_H258		
Confidence	99.95%		
Date	Tue Oct 27 13:55:09 GMT 2020		
Rank	3		
% Identity	31%		
Aligned Residues	93		
SCOP info	Prealbumin-like	Starch-binding domain-like	Starch-binding domain
Template	d1cgta2		
Resolution	2.00		
Model Dimensions (Å)	X:35.409	Y:39.555	Z:31.247

[Show / Hide SS confidence](#) [Show / Hide Conservation and Alignment quality](#)




[Detailed help on interpreting your alignment](#)

**Predicted Secondary structure**



**Predicted Secondary structure**

Download: [Text version](#) [FASTA pairwise alignment](#) [3D Model in PDB format](#)



[View in JSmol](#)

[Send structure to FirstGlance for more viewing options](#)

---

Phyre is now FREE for commercial users!

All images and data generated by Phyre2 are free to use in any publication with acknowledgement

Please cite: The Phyre2 web portal for protein modeling, prediction and analysis  
Kelley LA et al. *Nature Protocols* 10, 845-858 (2015) [paper] [citation link]

© Structural Bioinformatics Group, Imperial College, London  
Lawrence Kelley, Michael Sternberg  
Disclaimer  
[Terms and Conditions](#)

   
elixir UNITED KINGDOM

   
BBSRC Phyre2 is part of Genome3D

PDB stránka s načítanými údajmi pre PDB kód: 1CGT (templát):

Vzájomné porovnanie terciárnych štruktúr bude ukázané na porovnaní modelu C-terminálneho úseku proteínu genetonín-1 (bol namodelovaný úsek sekvencie Ser261-Trp355 z celkového úseku Gly260-His358) s reálnou štruktúrou škrob-viažucej domény z rodiny CBM20, ktorá je prítomná v enzýme cyklodextrínglukanotransferáza z *Bacillus circulans* (úsek templátu: Gly582-Trp683). Z výsledkov Phyre2 bol teda zvolený model č. 3 – „d1cgta2“ (PDB kód: 1CGT) s charakteristikou: 94% pokrytie sekvencie, 100% istota a 31% sekvenčná identita na danom prekryve. Treba povedať, že rovnako kvalitné výsledky boli poskytnuté aj pre model č. 1 – „d1cyga2“ (PDB kód: 1CYG; cyklodextrínglukanotransferáza z *Bacillus stearothermophilus*). Model č. 3 však bol zvolený kvôli dostupnosti literatúry, v ktorej bola terciárna štruktúra enzýmu popísaná (PubMed ID: 1826034).

Pre samotné porovnanie štruktúr je potrebné pripraviť si koordináty aj modelu, aj templátu. Štruktúra modelu sa získa uložením z výsledkov Phyre2 serveru ako model č. 3. Štruktúra templátu sa získa z databázy PDB podľa kódu 1CGT. Tento súbor však obsahuje koordináty pre celú molekulu cyklodextrínglukanotransferázy (684 zvyškov), takže pre ďalšiu prácu je výhodné si z PDB súboru vystrihnúť len koordináty pre časť štruktúry, ktorá slúžila ako templát (a ktorá v podstate predstavuje celú škrob-viažucu doménu typu CBM20 tohto enzýmu), t.j. úsek Gly582-Trp683.

Takto boli pripravené dva súbory štruktúr v PDB formáte: (i) model č. 3 C-terminálnej oblasti ľudského genetonínu-1 – „d1cgta2\_3.pdb“, t.j. úsek Ser261-Trp355 (vo výsledkoch Phyre2 je už upravené čislovanie Ser2-Trp95; pričom číslica „3“ v názve súboru naznačuje, že to je model č. 3); a (ii) štruktúra škrob-viažucej domény z cyklodextrínglukanotransferázy z *Bacillus circulans* – „1CGT\_CBM20.pdb“, t.j. úsek Gly582-Trp683.


Na porovnávanie terciárnych štruktúr proteínov je tiež možné využiť rôzne programy, prípadne servery; jednu z dobre etablovaných možností predstavuje server MultiProt. Pre uskutočnenie porovnania štruktúr je potrebné si súbory porovnávaných štruktúr uložiť do ZIP súboru. Po načítaní sú serverom poskytnuté výsledky vo forme zrovnania sekvencií založenom na štruktúre, pričom porovnanie je charakterizované dvomi parametrami: (i) počtom korešpondujúcich Ca atómov („Alignment Size“); a (ii) hodnotou odchýlky RMSD („root mean square deviation“) – v jednotkách „ $\text{\AA}$ “, ktorá udáva mieru priemernej vzdialenosť medzi korešpondujúcimi Ca atómami. Dve porovnávané štruktúry proteínov sú si tým viac podobné, t.j. ich vzájomná štruktúrna superpozícia (prekryv; „structure overlay“; „structural superimposition“) je tým lepšia, čím vyšší je počet korešpondujúcich Ca atómov a čím menšia je hodnota odchýlky RMSD. Počet korešpondujúcich Ca atómov je vždy menší, resp. môže byť maximálne taký veľký, ako je počet Ca atómov menšej porovnávanej molekuly proteínu.

MultiProt sever poskytuje spravidla viacero výsledkov, z ktorých je potrebné vždy zvoliť tie, ktoré splňajú kritéria o čo najväčšom možnom počte korešpondujúcich Ca atómov a čo najnižšej hodnote odchýlky RMSD. Pre prípad štruktúrneho porovnania modelu C-terminálnej oblasti genetonínu-1

a reálnej štruktúry škrob-viažucej domény z rodiny CBM20 prítomnej v cyklodextrínglukanotransferáze sú to výsledky v 1. riadku, t.j. „Alignment Size“: 93 a „RMSD“: 0,59 Å. Počet korešpondujúcich Ca atómov v porovnávaných proteínových molekulách bol 95 pre C-terminálny región genetonínu-1 (súbor: „d1cgta2\_3.pdb“) a 102 pre škrob-viažucu doménu (súbor: „1CGT\_CBM20.pdb“). Pre uvedené výsledky superpozície (prekryvu) je nakoniec potrebné stiahnuť zo serveru súbor „aligned.pdb“, v ktorom sú uložené koordináty oboch proteínových molekúl po ich vzájomnej superpozícii a ktorý je možné vo vhodnom programe zobraziť (obr. 6.3).

Úvodná web-stránka serveru MultiProt:

<http://bioinfo3d.cs.tau.ac.il/MultiProt/>



[\[Back to Home Page\]](#)

PDB IDs separated by a space:

(e.g. 1adj:A 1hc7:A 1v95)

Upload zip file of pdb structures:

Prehľadávať... Nie je zvolený súbor.


Accuracy (in Angstroms):

3

Sequence Order:

Yes  No

Výsledky zo serveru MultiProt:




Protein	Number of C-alpha atoms
1CGT_CBM20	102
d1cgta2_3	95

Number of aligned molecules : 2			
Alignment Size	RMSD	Molecules	PDB alignment
<a href="#">93</a>	0.59	1CGT_CBM20 d1cgta2_3	<a href="#">aligned.pdb</a>
<a href="#">15</a>	1.84	1CGT_CBM20 d1cgta2_3	<a href="#">aligned.pdb</a>
<a href="#">15</a>	2.11	1CGT_CBM20 d1cgta2_3	<a href="#">aligned.pdb</a>

Zovnanie sekvencií generované serverom MultiProt:

**MultiProt**




Number of aligned molecules : 2

Alignment Size	RMSD	Molecules	PDB alignment
<a href="#">93</a>	0.59	1CGT_CBM20 d1cgta2_3	<a href="#">aligned.pdb</a>

Alignment syntaxis: *ChainID.AminoAcidCode.ResidueNumber*

1CGT_CBM20	d1cgta2_3
A G 582	S 2
A D 583	Q 3
A Q 584	Q 4
A V 585	V 5
A T 586	S 6
A V 587	V 7
A R 588	R 8
A F 589	F 9
A V 590	Q 10
A V 591	V 11
A N 592	H 12
A N 593	Y 13
A A 594	V 14
A S 595	T 15
A T 596	S 16
A T 597	T 17
A L 598	D 18
A G 599	V 19
A Q 600	Q 20
A N 601	F 21
A L 602	I 22
A Y 603	A 23
A L 604	V 24
A T 605	T 25
A G 606	G 26
A N 607	D 27
A V 608	H 28
A A 609	E 29
A E 610	C 30
A L 611	L 31
A G 612	G 32
A A 620	R 33
A I 621	W 34
A G 622	N 35
A P 623	T 36
A A 624	Y 37
A F 625	I 38
A N 626	P 39
A Q 627	L 40
A V 628	H 41
A I 629	Y 42
A H 630	N 43
A Q 631	K 44
A Y 632	D 45
A P 633	G 46
A T 634	F 47
A W 635	W 48
A Y 636	S 49
A Y 637	H 50
A D 638	S 51
A V 639	I 52
A S 640	F 53
A V 641	L 54
A P 642	P 55
A A 643	A 56
A G 644	D 57
A K 645	T 58
A Q 646	V 59
A L 647	V 60
A E 648	E 61
A F 649	W 62
A K 650	K 63
A F 651	F 64
A F 652	V 65
A K 653	L 66
A K 654	V 67
A N 655	E 68
A G 656	G 70
A S 657	G 71
A T 658	V 72
A I 659	T 73
A T 660	R 74
A W 661	W 75
A E 662	E 76
A S 663	E 77
A G 664	C 78
A S 665	S 79
A N 666	N 80
A H 667	R 81
A T 668	F 82
A F 669	L 83
A T 670	E 84
A T 671	T 85
A P 672	G 86
A G 675	E 88
A T 676	D 89
A A 677	K 90
A T 678	V 91
A V 679	V 92
A T 680	H 93
A V 681	A 94
A N 682	W 95
A W 683	W 96



**Obr. 6.3.** Znázornenie (a) modelu C-terminálnej oblasti ľudského genetonínu-1 a (b) terciárnej štruktúry škrob-viažucej domény z rodiny CBM20 cyklodextrínglukanotransferázy z *Bacillus circulans*. Elementy sekundárnej štruktúry –  $\beta$ -vlákna – sú zobrazené ako tyrkysové šípky. (c) Štruktúrny prekryv (znázornený stereo; polypeptidový reťazec ako líniu) modelu potenciálnej škrob-viažucej domény z genetonínu-1 (tyrkysová) a reálnej škrob-viažucej domény z cyklodextrínglukanotransferázy (oranžová). Selektované zvyšky (modré pre genetonín-1; červené pre cyklodextrínglukanotransferázu) sú dôležité pre funkciu väzby  $\alpha$ -glukánov pre škrob-viažuce domény z rodiny CBM20. Zobrazené v programe WebLabViewerLite (Molecular Simulations, Inc.).

## 7. Praktické úlohy a cvičenia

### 7.1. Sledovanie veľkosti genómov rôznych mikroorganizmov

#### Zadanie

Na základe PubMed ID čísel pre jednotlivé literárne záznamy, zistite a navzájom porovnajte veľkosti kompletnejších genómov vybraných mikroorganizmov, ako aj doplnite ďalšie údaje do tab. 7.1:

- časopis, v ktorom bola štúdia uverejnená;
- rok vydania;
- doménu prokaryotov – buď *Bacteria* alebo *Archaea*;
- veľkosť genómu v bázových pároch;
- počet génov kódujúcich proteíny (ORF).

**Tabuľka 7.1.** Príklady organizmov s kompletne sekvenovaným genómom.

Č.	Mikroorganizmus	PubMed	Časopis	Rok	Doména	Veľkosť genómu	ORF
1	<i>Haemophilus influenzae</i>	7542800					
2	<i>Mycoplasma genitalium</i>	7569993					
3	<i>Methanococcus jannaschii</i>	8688087					
4	<i>Helicobacter pylori</i>	9252185					
5	<i>Escherichia coli</i>	9278503					
6	<i>Bacillus subtilis</i>	9384377					
7	<i>Archaeoglobus fulgidus</i>	9389475					
8	<i>Borrelia burgdorferi</i>	9403685					
9	<i>Mycobacterium tuberculosis</i>	9634230					
10	<i>Treponema pallidum</i>	9665876					
11	<i>Thermotoga maritima</i>	10360571					
12	<i>Deinococcus radiodurans</i>	10567266					
13	<i>Vibrio cholerae</i>	10952301					
14	<i>Yersinia pestis</i>	11586360					
15	<i>Shewanella oneidensis</i>	12368813					

## **7.2. In silico analýza triózafosfátizomerázy**

### *Zadanie*

Vykonajte bioinformatickú analýzu enzýmu triózafosfátizomeráza pochádzajúceho zo 40 rôznych zdrojov zahŕňajúcich baktérie, archeóny a eukaryoty podľa tab. 7.2.

- (1) Vytvorte si priečinok „TIM“.
- (2) Všetkých 40 sekvencií TIM zhromaždite z databázy UniProt do vstupného súboru („TIM.txt“; textový súbor) vhodného pre program Clustal-Omega.
- (3) Na EBI serveri zrovnejte sekvencie TIM v programe Clustal-Omega – <http://www.ebi.ac.uk/Tools/msa/clustalo/> – získajte dva súbory: „TIM\_aln.txt“ (alignment „with character counts“) a „TIM\_fas.txt“ (formát Pearson/FASTA); dodržte vstupné poradie sekvencií (input order).
- (4) Súbor „TIM\_aln.txt“ otvorte v programe MS-Word a v zrovnaných sekvenciách zvýraznite žltým podfarbením aminokyselinové zvyšky aktívneho miesta (Asn10, Lys12, His95, Glu165 v sekvencii triózafosfátizomerázy zo *Saccharomyces cerevisiae*); súbor uložte ako dokument „TIM\_aln.doc“.
- (5) Vypočítajte hodnoty CL, SI a SS.
- (6) Na EBI serveri v rámci programu Simple Phylogeny – [http://www.ebi.ac.uk/Tools/phylogeny/simple\\_phylogeny/](http://www.ebi.ac.uk/Tools/phylogeny/simple_phylogeny/) – vypočítajte dva evolučné stromy pre TIM – s uvažovaním medzier v sekvenciách („TIM\_off.txt“) a s ich ignorovaním („TIM\_on.txt“) – na základe finálneho súboru „TIM\_fas.txt“.
- (7) Vypočítané evolučné stromy zobrazte v programe iTOL (interactive Tree of Life; <https://itol.embl.de/>), vložte ako exportované obrázky (napr. PNG) do súboru „TIM\_aln.doc“, porovnajte a zapíšte diskusiu celej práce.

**Tabuľka 7.2.** Zoznam študovaných triózafosfátizomeráz.

Č. Zdroj		Skratka	UniProt	Dĺžka
<i>Bacteria</i>				
1	<i>Agrobacterium tumefaciens</i>	Agrtu	Q8UEY3	256
2	<i>Nostoc</i> sp. PCC 7120	Nosspp	Q8YP17	241
3	<i>Bacillus anthracis</i>	Bacan	Q81X76	251
4	<i>Bifidobacterium longum</i>	Biflo	Q8G6D5	267
5	<i>Borrelia burgdorferi</i>	Borbu	Q59182	253
6	<i>Chlamydia pneumoniae</i>	Chlpn	Q9Z6J6	254
7	<i>Deinococcus radiodurans</i>	Deira	Q9RUP5	244
8	<i>Escherichia coli</i>	Escco	P0A858	255
9	<i>Haemophilus influenzae</i>	Haein	P43727	263
10	<i>Mycobacterium tuberculosis</i>	Myctu	P9WG42	261
11	<i>Mycoplasma genitalium</i>	Mypge	P47670	244
12	<i>Neisseria meningitidis</i>	Neime	Q9JW31	251
13	<i>Salmonella typhimurium</i>	Salty	Q8ZKP7	255
14	<i>Staphylococcus aureus</i>	Staaau	Q5HHP3	253
15	<i>Streptococcus mutans</i>	Stcmu	P72484	252
16	<i>Streptomyces coelicolor</i>	Strco	Q9Z520	258
17	<i>Synechocystis</i> sp. PCC 6803	Synsp	Q59994	242
18	<i>Thermotoga maritima</i>	Thtma	P36204	255 (400-654)
19	<i>Vibrio cholerae</i>	Vibch	Q9KNR1	257
20	<i>Yersinia pestis</i>	Yerpe	Q8ZJK9	255
<i>Archaea</i>				
21	<i>Aeropyrum pernix</i>	Aerpe	Q9YBR1	223
22	<i>Archaeoglobus fulgidus</i>	Arcfu	O28965	223
23	<i>Haloarcula marismortui</i>	Haama	Q5V4J7	215
24	<i>Halobacterium salinarium</i>	Habsa	Q9HQS4	214
25	<i>Methanopyrus kandleri</i>	Mepka	Q8TUT9	226
26	<i>Methanosarcina mazei</i>	Mesma	Q8PXE2	222
27	<i>Pyrobaculum aerophilum</i>	Pybae	Q8ZX28	227
28	<i>Pyrococcus furiosus</i>	Pycfu	P62002	228
29	<i>Sulfolobus solfataricus</i>	Sulso	Q97VM8	227
30	<i>Thermoproteus tenax</i>	Thpte	Q8NKN9	226
<i>Eucarya</i>				
31	<i>Arabidopsis thaliana</i> (mouse-ear cress)	Arath	Q9SKP6	255 (61-315)
32	<i>Aspergillus nidulans</i> (fungi)	Aspni	P04828	249
33	<i>Caenorhabditis elegans</i> (nematode)	Caeel	Q10657	247
34	<i>Drosophila melanogaster</i> (fruit fly)	Drome	P29613	247
35	<i>Gracilaria verrucosa</i> (red alga)	Grave	P48492	250
36	<i>Homo sapiens</i> (human; isoform 1)	Homsa	P60174	249
37	<i>Oryctolagus cuniculus</i> (rabbit, isoform 1)	Orlcu	P00939	249
38	<i>Oryza sativa</i> (rice)	Orysa	P48494	253
39	<i>Pan troglodytes</i> (chimpanzee)	Pantr	P60175	249
40	<i>Saccharomyces cerevisiae</i> (yeast)	Sacce	P00942	248

### **7.3. Bioinformatická analýza pektolytických enzýmov z rodiny GH28**

#### *Zadanie*

Vykonajte bioinformatickú analýzu pektolytických enzýmov z rodiny GH28 pochádzajúcich z 25 rôznych zdrojov zahrňajúcich baktérie a eukaryoty podľa tab. 7.3.

- (1) Vytvorte si priečinok „GH28“.
- (2) Všetkých 25 sekvencií pektolytických enzýmov zhromaždite z databázy UniProt do vstupného súboru („GH28.txt“; textový súbor) vhodného pre program Clustal-Omega.
- (3) Na EBI serveri zrovnaťte sekvencie enzýmov z rodiny GH28 v programe Clustal-Omega – <http://www.ebi.ac.uk/Tools/msa/clustalo/> – získajte dva súbory: „GH28\_aln.txt“ (alignment „with character counts“) a „GH28\_fas.txt“ (formát Pearson/FASTA); dodržte vstupné poradie sekvencií (input order).
- (4) Súbor „GH28\_aln.txt“ otvorte v programe MS-Word a v zrovnaných sekvenciách zvýraznite žltým podfarbením konzervované sekvenčné regióny (udané pre tri reprezentatívne sekvencie nižšie); súbor uložte ako dokument „GH28\_aln.doc“.

Konzervované úseky vybraných členov rodiny GH28:

Protein č. 4: Aspni_PG	178_NTD	201_DD	222_GHG	256_RIK	Y291
Protein č. 21: Asptu_XGH	205_NTD	228_DD	250_SHG	284_GIK	Y322
Protein č. 22: Aspac_RG	193_GLD	215_DE	237_SGG	269_MIK	W302

- (5) Vypočítajte hodnoty CL, SI a SS.
- (6) Na EBI serveri v rámci programu Simple Phylogeny – [http://www.ebi.ac.uk/Tools/phylogeny/simple\\_phylogeny/](http://www.ebi.ac.uk/Tools/phylogeny/simple_phylogeny/) – vypočítajte dva evolučné stromy pre enzýmy z rodiny GH28 – s uvažovaním medzier v sekvenciách („GH28\_off.txt“) a s ich ignorovaním („GH28\_on.txt“) – na základe finálneho súboru „GH28\_fas.txt“.
- (7) Vypočítané evolučné stromy zobrazte v programe iTOL (interactive Tree of Life; <https://itol.embl.de/>), vložte ako exportované obrázky (napr. PNG) do súboru „GH28\_aln.doc“, porovnajte a zapísťte diskusiu celej práce.

**Tabuľka 7.3.** Zoznam študovaných pektolytických enzýmov z rodiny GH28.

Č.	Enzým	Zdroj	Ríša	Skratka	EC	UniProt
1	Polygalakturonáza	<i>Erwinia carotovora</i>	Baktérie	Erwca_PG	3.2.1.15	P26509
2	Polygalakturonáza	<i>Ralstonia solanacearum</i>	Baktérie	Ralso_PG	3.2.1.15	P20041
3	Polygalakturonáza	<i>Thermotoga maritima</i>	Baktérie	Thema_PG	3.2.1.15	Q9WYR8
4	Polygalakturonáza	<i>Aspergillus niger</i>	Huby	Aspni_PG	3.2.1.15	P26214
5	Polygalakturonáza	<i>Aspergillus parasiticus</i>	Huby	Asppa_PG	3.2.1.15	P49575
6	Polygalakturonáza	<i>Claviceps purpurea</i>	Huby	Clapu_PG	3.2.1.15	P78607
7	Polygalakturonáza	<i>Fusarium moniliforme</i>	Huby	Fusmo_PG	3.2.1.15	Q07181
8	Polygalakturonáza	<i>Kluyveromyces marxianus</i>	Huby	Kluma_PG	3.2.1.15	O13478
9	Polygalakturonáza	<i>Penicillium expansum</i>	Huby	Penex_PG	3.2.1.15	O59925
10	Polygalakturonáza	<i>Saccharomyces cerevisiae</i>	Huby	Sacce_PG	3.2.1.15	P47180
11	Polygalakturonáza	<i>Actinidia deliciosa</i>	Rastliny	Actde_PG	3.2.1.15	P35336
12	Polygalakturonáza	<i>Lycopersicon esculentum</i>	Rastliny	Lyces_PG	3.2.1.15	P05117
13	Polygalakturonáza	<i>Malus domestica</i>	Rastliny	Maldo_PG	3.2.1.15	P48978
14	Polygalakturonáza	<i>Phaedon cochleariae</i>	Hmyz	Phaco_PG	3.2.1.15	O97400
15	Exopolygalakturonáza	<i>Erwinia chrysanthemi</i>	Baktérie	Erwch_EPG	3.2.1.82	P15922
16	Exopolygalakturonáza	<i>Ralstonia solanacearum</i>	Baktérie	Ralso_EPG	3.2.1.82	Q53241
17	Exopolygalakturonáza	<i>Yersinia enterocolitica</i>	Baktérie	Yeren_EPG	3.2.1.82	O68975
18	Exopolygalakturonáza	<i>Aspergillus tubingensis</i>	Huby	Asptu_EPG	3.2.1.67	Q00293
19	Exopolygalakturonáza	<i>Fusarium oxysporum</i>	Huby	Fusox_EPG	3.2.1.67	O74255
20	Peľová polygalakturonáza	<i>Zea mays</i>	Rastliny	Zeama_PPG	3.2.1.67	P26216
21	Xylogalakturonanhydroláza	<i>Aspergillus tubingensis</i>	Huby	Asptu_XGH	3.2.1.-	Q9UUZ2
22	Ramnogalakturonáza	<i>Aspergillus aculeatus</i>	Huby	Aspac_RG	3.2.1.-	Q00001
23	Ramnogalakturonáza A	<i>Aspergillus niger</i>	Huby	AspniA_RG	3.2.1.-	P87160
24	Ramnogalakturonáza B	<i>Aspergillus niger</i>	Huby	AspniB_RG	3.2.1.-	P87161
25	Ramnogalakturonáza	<i>Botryotinia fuckeliana</i>	Huby	Botfu_RG	3.2.1.-	P87247

## 7.4. Bioinformatická analýza $\alpha$ -amyláz z rodiny GH13

### Zadanie

Vykonajte bioinformatickú analýzu  $\alpha$ -amyláz z rodiny GH13 pochádzajúcich z rôznych zdrojov, ktoré na základe sekvenčnej podobnosti patria do viac ako 10 podrodín tejto rodiny podľa tab. 7.4.

- (1) Vytvorte si priečinok „GH13“.
- (2) Všetkých 28 sekvencií  $\alpha$ -amyláz zhromaždite z databázy UniProt do vstupného súboru („GH13.txt“; textový súbor) vhodného pre program Clustal-Omega.
- (3) Na EBI serveri zrovnajte sekvencie enzymov z rodiny GH13 v programe Clustal-Omega – <http://www.ebi.ac.uk/Tools/msa/clustalo/> – získajte dva súbory: „GH13\_aln.txt“ (alignment „with character counts“) a „GH13\_fas.txt“ (formát Pearson/FASTA); dodržte vstupné poradie sekvencií (input order).
- (4) Súbor „GH13\_aln.txt“ otvorte v programe MS-Word a v zrovnaných sekvenciách zvýraznite tri konzervované sekvenčné regióny (KSR) okolo katalytických zvyškov: Asp227 (bez signálneho peptidu – 21 zvyškov: 206), Glu251 (230) a Asp318 (297) (počítanie v  $\alpha$ -amyláze z *Aspergillus oryzae*; regióny sú: GLRIDTVKH, EVLD a FVENHD). Zároveň skontrolujte, či sú sekvencie všetkých  $\alpha$ -amyláz správne zrovnané, t.j. či pre každú z 28 sekvencií boli identifikované všetky tri katalyticke zvyšky (v selektovaných KSR). Tiež rovnako zvýraznite ďalšie štyri KSR: 56\_GFTAIWITP (začiatok regiónu v sekvencii  $\alpha$ -amylázy z *Aspergillus oryzae* s uvažovaním signálneho peptidu: Gly77), 117\_DVVANH (Asp138), 173\_LPDL (Leu194) a 323\_GPIIYAGQ (Gly344); súbor uložte ako dokument „GH13\_aln.doc“. Ak niektoré KSR nie sú správne zrovnané, je potrebné zrovnanie sekvencií manuálne upraviť a tieto zmeny následne preniesť do zrovnania vo formáte Pearson/FASTA (súbor „GH13\_fas.txt“), ktorý bude slúžiť na výpočet evolučného stromu.
- (5) Vypočítajte hodnoty CL, SI a SS – z finálneho zrovnania (po prípadnej manuálnej úprave).
- (6) Na EBI serveri v rámci programu Simple Phylogeny – [http://www.ebi.ac.uk/Tools/phylogeny/simple\\_phylogeny/](http://www.ebi.ac.uk/Tools/phylogeny/simple_phylogeny/) – vypočítajte dva evolučné stromy pre enzymy z rodiny GH13 – s uvažovaním medzier v sekvenciách („GH13\_off.txt“) a s ich ignorovaním („GH13\_on.txt“) – na základe finálneho súboru „GH13\_fas.txt“.
- (7) Vypočítané evolučné stromy zobrazte v programe iTOL (interactive Tree of Life; <https://itol.embl.de/>), vložte ako exportované obrázky (napr. PNG) do súboru „GH13\_aln.doc“, porovnajte a zapíšte diskusiu celej práce.


**Tabuľka 7.4.** Zoznam študovaných  $\alpha$ -amyláz z rodiny GH13.

Č.	Organizmus	UniProt	Skratka	Dĺžka	Podrodina
1	<i>Aspergillus oryzae</i>	P0C1B3	Aspor_1	499	13_1
2	<i>Saccharomyces fibuligera</i>	D4P4Y7	Sacf1_1	494	13_1
3	<i>Bacillus amyloliquefaciens</i>	P00692	Bacam_5	514	13_5
4	<i>Halothermothrix orenii</i>	B8CZ54	Halor_5	623	13_5
5	<i>Hordeum vulgare</i>	P00693	Horvu_6	438	13_6
6	<i>Oryza sativa</i>	P17654	Orysa_6	434	13_6
7	<i>Pyrococcus woesei</i>	Q7LYT7	Pyrwo_7	460	13_7
8	<i>Thermococcus hydrothermalis</i>	O93647	Thehy_7	457	13_7
9	<i>Drosophila melanogaster</i>	P08144	Drome_15	494	13_15
10	<i>Tenebrio molitor</i>	P56634	Tenmo_15	471	13_15
11	<i>Gallus gallus</i>	Q98942	Galga_24	512	13_24
12	<i>Homo sapiens</i> (sliny)	P04745	Homsa_24	511	13_24
13	<i>Aeromonas hydrophila</i>	P22630	Aerhy_27	464	13_27
14	<i>Xanthomonas campestris</i>	Q56791	Xanca_27	475	13_27
15	<i>Bacillus subtilis</i>	Q45520	Bacsu_28	477	13_28
16	<i>Lactobacillus amylovorus</i>	Q48502	Lacam_28	953	13_28
17	<i>Pseudoalteromonas haloplanktis</i>	P29957	Pseha_32	669	13_32
18	<i>Streptomyces limosus</i>	P09794	Strli_32	566	13_32
19	<i>Halothermothrix orenii</i>	Q8GPL8	Halor_36	515	13_36
20	<i>Dictyoglomus thermophilum</i>	P14899	Dicth_36	499	13_36
21	<i>Uncultured bacterium</i>	D9MZ14	Uncba_37	639	13_37
22	<i>Photobacterium profundum</i>	Q6LIA8	Phopr_37	687	13_37
23	<i>Roseburia</i> sp. A2-194	Q3LB10	Rossp_41	1674	13_41
24	<i>Micrococcus</i> sp. 207	Q06812	Micsp_41	1104	13_41
25	<i>Bacillus aquimaris</i>	G8IJA7	Bacaq_xx	512	xx
26	<i>Geobacillus thermoleovorans</i>	G8N704	Geoth_xx	511	xx
27	<i>Haloarcula hispanica</i>	Q4A3E0	Halhi_yy	433	yy
28	<i>Natronoarchaeum philippinense</i>	A0A285N7G2	Natph_yy	511	yy


## 7.5. Analýza enzýmov z rodiny GH28 pomocou metódy HCA

V sekvencii polygalakturonázy z *Aspergillus niger* (Aspni\_PG) identifikujte úseky 18\_NTD, 41\_DD, 62\_GHG, 96\_RIK a zvyšok Tyr131. Potom k nim nájdite korešpondujúce úseky v sekvenciach xylogalakturonanhydrolázy z *Aspergillus tubigensis* (Asptu\_XGH) a rammogalakturonázy z *Aspergillus aculeatus* (Aspac\_RG). Výsledky dajte do súvisu s výsledkami *in silico* analýzy pektolytických enzýmov z rodiny GH28, najmä s ohľadom na ich konzervované úseky (zadanie č. 7.3, bod č. 4).


Aspni\_PG



Asptu\_XGH



Aspac\_RG



## 7.6. Analýza hémových kataláz pomocou metódy HCA


### Teória

Hémové peroxidázy sú oxidoreduktázy odpovedajúce na rôzne formy oxidačného stresu. Trieda Class I hémových peroxidáz obsahuje tri skupiny enzýmov: (i) katalázy-peroxidázy (CP); (ii) askorbát-peroxidázy (APX); a (iii) cytochróm c peroxidázy (CCP). Kataláza-peroxidáza (CP) je jediným enzýmom skupiny, ktorý má *katalázovú* aktivitu, t.j. je schopný aj oxidovať, aj redukovať  $\text{H}_2\text{O}_2$ . Ostatné *nekatalázové* enzýmy (APX a CCP) dokážu peroxid vodíka len redukovať. K funkcií hémových peroxidáz je potrebná prostetická skupina – ióny Fe vo forme hému. Hém je viazaný dvomi His zvyškami: tzv. vzdialená strana väzbového zoskupenia – bližšie k N-koncu proteínu (His87 v CP z *Archaeoglobus fulgidus*) a tzv. blízka strana väzbového zoskupenia – ďalej od N-konca proteínu (His249 v CP z *Archaeoglobus fulgidus*). V sekvenции všetkých členov triedy Class I hémových peroxidáz sú tri konzervované regióny, ktoré obsahujú funkčne esenciálne aminokyselinové zvyšky (v CP z *Archaeoglobus fulgidus*): (i) His87 (vzdialená strana): 79\_PLFIRLAW**HSAGSYR**\_93; (ii) His249 (blízka strana): 242\_VALIAGG**HAFGKC**\_254; a (iii) Asp359 (vodíková väzba s His249): 353\_PRMLTAD**LALRF**\_364. CP obsahujú v porovnaní s APX a CCP duplikát celej katalytickej domény (sú zhruba 2x dlhšie). Originál, t.j. katalyticky aktívna časť proteínu, sa nachádza v N-terminálnej časti, kým duplikát, ktorý je katalyticky neaktívny, sa nachádza v C-terminálnej oblasti molekuly. Duplikát je katalyticky neaktívny preto, že aj keď obsahuje všetky tri konzervované regióny, His ligandy sú substituované inými zvyškami.


### Zadanie

- (1) Vytvorte na ploche Vášho počítača priečinok s názvom „HCA“.
- (2) Z databázy UniProt získajte sekvencie enzýmov: (i) kataláza-peroxidáza z *Archaeoglobus fulgidus* (UniProt: O28050); (ii) askorbát-peroxidáza z *Arabidopsis thaliana* (cytosolic; Q05431); (iii) askorbát-peroxidáza z *Arabidopsis thaliana* (thylakoid-bound; Q42593); a (iv) cytochróm c peroxidáza zo *Saccharomyces cerevisiae* (P00431).
- (3) Pomocou aktuálneho HCA-servera vytvorte na internete HCA obrazy všetkých štyroch sekvencií hémových peroxidáz a uložte ich do priečinku „HCA“ vo formáte PDF.
- (4) Na vytlačenom HCA obrázku študovaných hémových peroxidáz identifikujte a farebne vyznačte: (i) tri konzervované sekvenčné regióny (KSR) obsahujúce His87, His249 a Asp359 v HCA obrazze CP z *A. fulgidus* (Arcfu\_CP.txt); (ii) tri KSR (t.j. oblasti korešpondujúce His87, His249 a Asp359) v oboch APX a CCP (Arath\_APX, Arath\_APXT a Sacce\_CCP); a (iii) oblasti korešpondujúce His87, His249 a Asp359 v C-terminálnom duplikáte katalytickej domény CP z *A. fulgidus*.


## Arcfu\_CP




## Arath\_APX



## Arath\_APXT



## Sacce\_CCP



## **7.7. Analýza škrob-viažucich domén pomocou metódy HCA**

### *Teória*


Škrob-viažuca doména (starch-binding domain; SBD) je klasifikovaná ako tzv. modul z rodiny CBM20, t.j. „carbohydrate-binding module family 20“. Táto doména umožňuje amylolytickému enzymu viazať a degradovať surový (nezmazovatený) škrob. CBM20 sa môže nachádzať v  $\alpha$ -amylázach,  $\beta$ -amylázach a glukoamylázach z baktérií, archeónov, kvasiniek a vláknitých húb, ktorých katalyticke domény sú navzájom sekvenčne nepodobné; ale napr. aj v rastlinných 4- $\alpha$ -glukanotransferázach. U živočíchov môže byť súčasťou glukánfosfatázy laforín, prípadne aj doteraz bližšie necharakterizovaného proteínu genetonín-1, pričom u oboch funguje skôr ako glycogen-viažuca doména (glycogen-binding domain; GBD). Sekvenčne príbuzná doména SBD/GBD typu CBM48 sa môže nachádzať aj v ďalších regulačných proteínoch, ktoré sú zapojené do regulácie metabolizmu škrobu u rastlín (proteín-4 nadbytku škrobu; SEX-4) a glycogenu u živočíchov (súčasť  $\beta$ -podjednotky AMP-aktivovanej proteínovej kinázy; AMPK $\beta$ ).

### *Zadanie*


Na HCA zobrazení vyššie spomenutých enzymov a proteínov identifikujte ich škrob-, resp. glycogen-viažucu doménu. Vo všeobecnosti má doména vo všetkých prípadoch približne 100 aminokyselinových zvyškov, pričom sa môže nachádzať ako na N-, tak aj na C-konci proteínovej molekuly, prípadne aj vo vnútri proteínového reťazca. Pri identifikácii si pomôžte nasledovnými charakteristickými sekvenčnými črtami SBD typu CBM20 z amylolytických enzymov:

N-koniec domény  
~ 30 zvyškov  
LG-W  
~ 15 zvyškov  
P-W  
~ 15 zvyškov  
K  
~ 10 zvyškov  
W---N  
~ 15 zvyškov  
C-koniec domény


*Streptomyces griseus*  $\alpha$ -amylase




*Bacillus cereus*  $\beta$ -amylase




*Aspergillus niger* glucoamylase




*Homo sapiens* laforin




*Homo sapiens* genethonin-1



*Arabidopsis thaliana* SEX-4




*Rattus norvegicus* AMPK subunit  $\beta$ 1



## 7.8. Analýza $\alpha$ -glukozidáz s využitím nástroja BLAST

### Teória

Enzým oligo-1,6-glukozidáza (OGLU), EC 3.2.1.10, patrí medzi glykozidové hydrolázy. Ako  $\alpha$ -glukozidáza katalyzuje hydrolýzu  $\alpha$ -1,6-glukozidových väzieb v  $\alpha$ -glukánoch. V rámci  $\alpha$ -amylázovej enzýmovej rodiny GH13 tvorí tzv. oligo-1,6-glukozidázovú podrodinu spolu s niekoľkými ďalšími príbuznými enzýmovými špecifitami. Tieto enzýmy sú prevažne mikrobiálneho pôvodu. Bolo zistené, že k oligo-1,6-glukozidáze a enzýmom z jej podrodiny existujú u vyšších organizmov (živočíchy až cicavce) sekvenčne podobné proteíny, ktoré tvoria ťažké reťazce heteromérnych transportérov zodpovedných za prenos aminokyselín cez bunkovú membránu, tzv. proteíny rBAT a 4F2hc antigén. Oligo-1,6-glukozidáza je multidoménový enzým, zložený z troch domén (obr. 7.8): (i) N-terminálna katalytická doména A; (ii) doména B včlenená v katalytickej doméne; a (iii) C-terminálna doména C. Transportné proteíny majú podobné usporiadanie domén svojich proteínových molekúl, ale majú navyše N-terminálnu doménu (N-term.) a transmembránový segment (TM). Doména A v proteínoch rBAT a 4F2hc nemusí obsahovať katalytické zvyšky nevyhnutné pre funkciu  $\alpha$ -glukozidáz. Proteín 4F2hc navyše neobsahuje ani doménu B.



**Obr. 7.8.** Schéma oligo-1,6-glukozidázy a proteínov rBAT a 4F2hc.

### Zadanie

- (1) *In silico* analýza  $\alpha$ -glukozidáz z oligo-1,6-glukozidázovej podrodiny pomocou nástroja BLAST. Query: OGLU z *Bacillus cereus* (UniProt: P21332; dĺžka: 558); maximálny počet zachytených sekvencií: 500.
- (2) Vytvorte si priečinok „BLAST\_OGLU“.
- (3) Z databázy UniProt získajte aminokyselinovú sekvenciu OGLU (výsledok uložte).
- (4) So sekvenciou danej OGLU vykonajte štandardný proteínový BLAST (Max. target sequences: 500); kompletne výsledky uložte.

- (5) V predpripravených výsledkoch získaných pomocou nástroja BLAST (Max. target sequences: 5000) dostupných na web-stránke: [http://imb.savba.sk/~janecek/UCM/Tretiaci/BLAST/OGLU/OGLU\\_BLAST\\_5000.htm](http://imb.savba.sk/~janecek/UCM/Tretiaci/BLAST/OGLU/OGLU_BLAST_5000.htm) identifikujte ďalších 21 enzymov/proteínov (č. 2-22; tab. 7.8) a doplňte všetky príslušné údaje (vzorová tabuľka je tiež k dispozícii): [http://imb.savba.sk/~janecek/UCM/Tretiaci/BLAST/OGLU/OGLU\\_Tabulka\\_vzor.doc](http://imb.savba.sk/~janecek/UCM/Tretiaci/BLAST/OGLU/OGLU_Tabulka_vzor.doc)
- (6) Údaje pre 4F2hc antigén a rBAT proteíny (č. 23, 24 a 25; tab. 7.8) doplňte priamo z databázy GenBank (predpripravený BLAST pre 5000 zachytených sekvencií ich neobsahuje).
- (7) Všetkých 25 sekvencií zhromažďte z databáz GenBank a/alebo UniProt do vstupného súboru „OGLU.txt“.
- (8) Na EBI serveri zrovnaťte sekvencie v programe Clustal-Omega – získajte dva súbory: „OGLU\_aln.txt“ (alignment „with character counts“) a „OGLU\_fas.txt“ (formát Pearson/FASTA); dodržte vstupné poradie sekvencií (input order).
- (9) V zrovnaných sekvenciách, t.j. v súbore „OGLU\_aln.txt“ uloženého ako dokument súboru „OGLU\_aln.doc“, žltým podsvietením (ak sú prítomné) farebne zvýraznite charakteristické konzervované sekvenčné regióny (udané v sekvencii oligo-1,6-glukozidázy z *Bacillus cereus*), pričom sa zvlášť zamerajte na prítomnosť, resp. neprítomnosť troch katalytických zvyškov (najmä u transportných proteínov; hrubo označené kurzívou): 44\_GIDVIWLSP ... 98\_DLVVNH ... 167\_QPDLN ... 195\_GFRM**D**VINF ... 251\_MTVG**E**MPG ... 324\_YWNN**H**D ... 360\_GTPYIYQGE.
- (10) Na EBI serveri v rámci programu Simple-Phylogeny vypočítajte dva evolučné stromy pre študované enzymy a proteíny – s uvažovaním, resp. s ignorovaním medzier v sekvenciách „OGLU\_off.txt“ a „OGLU\_on.txt“. Evolučné stromy zobrazte v programe iTOL („circular“), exportujte ako PNG súbory a vložte pod zrovnanie do súboru „OGLU\_aln.doc“.
- (11) Pre zrovnané sekvencie (alignment) zistite konsenzuálnu dĺžku (CL), vypočítajte sekvenčnú identitu (SI) a podobnosť (SS) a výsledky spolu s diskusiou celej práce slovne zapíšte.
- (12) V priečinku „BLAST\_OGLU“ budú uložené nasledovné súbory:
- celý html súbor OGLU z databázy UniProt („OGLU\_seq.htm“);
  - Vaše výsledky z BLASTu (html súbor: „OGLU\_BLAST.htm“; Max. target sequences: 500);
  - doplnená tab. 7.8 s 25 zdrojmi (DOC súbor: „OGLU\_Tabulka.doc“);
  - vstupný súbor s 25 sekvenciami (textový súbor: „OGLU.txt“);
  - zrovnania sekvencií (súbory: „OGLU\_aln.txt“ a „OGLU\_fas.txt“);
  - zrovnanie vo formáte ALN („OGLU\_aln.doc“) so žltou zvýraznenými konzervovanými regiónmi a červenou inverziou zvýraznenými prípadnými katalytickými zvyškami (podľa bodu 9), vloženými obrázkami evolučných stromov (podľa bodu 10) a pod tým hodnoty CL, SI a SS a diskusia evolučných stromov;
  - vypočítané súbory (nie obrázky) evolučných stromov („OGLU\_off.txt“ a „OGLU\_on.txt“).


**Tabuľka 7.8.** Zoznam študovaných sekvencií a-glukozidáz.

Č.	Zdroj enzýmu	Enzým	Skratka	EC	Prístupové číslo	Dĺžka	Skóre
1	<i>Bacillus cereus</i>	Oligo-1,6-glukozidáza	Bacce_OGLU	3.2.1.10	sp P21332	558	1152
2		Oligo-1,6-glukozidáza	Bacth_OGLU	3.2.1.10	sp P29094		
3		Oligo-1,6-glukozidáza	Grbha_OGLU	3.2.1.10	gb ENH95997.1		
4		Oligo-1,6-glukozidáza	Anbfl_OGLU	3.2.1.10	gb GAC90225.1		
5		Oligo-1,6-glukozidáza	Bacsu_OGLU	3.2.1.10	gb AAG23399.1		
6		Trehalóza-6-fosfát hydroláza	Anbfl_T6PH	3.2.1.93	gb GAC89934.1		
7		Trehalóza-6-fosfát hydroláza	Gebst_T6PH	3.2.1.93	gb BAE45038.1		
8		Oligo-1,6-glukozidáza	Bacco_OGLU	3.2.1.10	sp Q45101		
9		Oligo-1,6-glukozidáza	Clocl_OGLU	3.2.1.10	gb ENZ09185.1		
10		Alfa-glukozidáza	Labpe_AGLU	3.2.1.20	gb CCC16900.1		
11		Oligo-1,6-glukozidáza	Clobo_OGLU	3.2.1.10	gb ENZ38195.1		
12		Oligo-1,6-glukozidáza	Arbgl_OGLU	3.2.1.10	gb BAC78840.1		
13		Alfa-glukozidáza	Gebst_AGLU	3.2.1.20	gb BAA12704.1		
14		Glykozidáza	Jabli_GLY	3.2.1.-	gb AAZ39207.1		
15		Glykozidáza	Rucgn_GLY	3.2.1.-	gb CCG93502.1		
16		Alfa-glukozidáza	Pecpe_AGLU	3.2.1.20	sp P43473		
17		Oligo-1,6-glukozidáza	Weith_OGLU	3.2.1.10	gb CCC56207.1		
18		Oligo-1,6-glukozidáza	Enbpu_OGLU	3.2.1.10	gb CAZ90594.1		
19		Hypotetický proteín	Cloha_HYPO	----	gb ENY93903.1		
20		Alfa-glukozidáza	Stcau_AGLU	3.2.1.20	gb ENM74527.1		
21		Oligo-1,6-glukozidáza	Bacsp_OGLU	3.2.1.10	sp P29093		
22		Oligo-1,6-glukozidáza	Rhisp_OGLU	3.2.1.10	gb CCF21491.1		
23		4F2hc antigén (isoform 2)	Homса_4F2	----	gb AAA35489.1	----	----
24		rBAT proteín	Salsa_rBAT	----	gb ACN60293.1	----	----
25		rBAT proteín	Homса_rBAT	----	gb AAA35500.1	----	----

## 7.9. Analýza škrob-viažucej domény amyláz s využitím nástroja BLAST

### Teória

Enzým cyklodextrínglukanotransferáza (CGTáza), EC 2.4.1.19, patrí medzi transferázy. Katalyzuje hydrolytické štiepenie  $\alpha$ -1,4-glukozidových väzieb (napr. v škrobe), pričom súčasne prenáša (transferázová aktivita) molekulu glukózy s následnou tvorbou cyklického sacharidu (cyklodextrínu). Vo všeobecnosti cyklizuje časť  $\alpha$ -1,4-D-glukánového reťazca tvorbou  $\alpha$ -1,4-D-glukozidovej väzby. CGTáza je multidoménový enzym, ktorý sa najčastejšie skladá z piatich domén (obr. 7.9). Na C-konci svojej proteínovej molekuly obsahuje tzv. škrob-viažucu doménu (starch-binding domain; SBD), ktorá je klasifikovaná ako tzv. modul z rodiny CBM20, t.j. „carbohydrate-binding module family 20“. Táto doména umožňuje enzymu viazať a degradovať surový (tepelne neupravený) škrob. CBM20 sa môže nachádzať aj v  $\alpha$ -amylázach,  $\beta$ -amylázach a glukoamylázach. Hoci tieto jednotlivé amylázy obsahujú sekvenčne nepodobné katalyticke domény, na svojich C-koncoch môžu mať odpovedajúcu SBD typu CBM20. Doména SBD typu CBM20 a jej homológ z rodiny CBM48 sa môžu nachádzať napr. v glukánfosfatázach zapojených do regulácie metabolizmu glykogénu u živočíchov (proteín laforín) a škrobu u rastlín (tzv. proteín nadbytku škrobu 4 – SEX-4), prípadne ako súčasť  $\beta$ -podjednotky AMP-aktivovanej proteínovej kinázy (AMPK $\beta$ ).



Obr. 7.9. Schéma CGTázy (SP, signálny peptid).

### Zadanie

- (1) *In silico* analýza škrob-viažúcich domén z rodiny CBM20 pomocou nástroja BLAST. Query: SBD CGTázy z *Bacillus circulans* (UniProt: P30920; dĺžka: 718; SBD: 613-718); maximálny počet zachytených sekvencií: 250.
- (2) Vytvorte si priečinok „BLAST\_CBM20“.
- (3) Z databázy UniProt získajte aminokyselinovú sekvenčiu SBD z danej CGTázy (výsledok uložte).
- (4) So sekvenčiou danej SBD vykonajte štandardný proteínový BLAST (Max. target sequences: 250); kompletne výsledky uložte.
- (5) Na výber databázy si (buď sami alebo po dohode s vyučujúcim) zvoľte niektorú vhodnú kombináciu pre „Organism“ a „Exclude“ z nasledovných možností pri vylúčení taxónu „Paenibacillus (taxid:44249)“: „Bacteria (taxid:2)“; „Archaea (taxid:2157)“; „Plants (taxid:3193)“; „Viridiplantae (taxid:33090)“; „Eucarya (taxid:2759)“;

„Fungi (taxid:4751)“; „Fungi/Metazoa group (taxid:33154)“; „Metazoa (taxid:33208)“ a Mammals (taxid:40674).

- (6) Vo výsledkoch získaných BLASTom identifikujte (na základe tab. 7.9) ďalších 29 enzýmov/proteínov spomedzi CGTáz, prípadne  $\alpha$ -amyláz,  $\beta$ -amyláz a glukoamyláz, ako aj ďalších príbuzných hypotetických enzýmov a proteínov (t.j. dohromady so vstupnou SBD 30), ktoré budú obsahovať motív SBD (~ 100 aminokyselinových zvyškov) podľa nasledovného vzoru: ~30 aa ... **lg-W** ... ~15 aa ... **p-W** ... ~15 aa ... **fKf** ... ~10 aa ... **W----n** ... ~15 aa (C-koniec domény). Požadované údaje – extrahované z výsledkov BLASTu – vhodne uložte do tab. 7.9.
- (7) Všetkých 30 sekvencií SBD – vystrihnutých z pôvodných sekvencií celých enzýmov a proteínov – zhromažďte z databáz GenBank a/alebo UniProt do vstupného súboru „SBD.txt“.
- (8) Na EBI serveri zrovnejte sekvencie SBD v programe Clustal-Omega – získajte dva súbory: „SBD\_aln.txt“ (alignment „with character counts“) a „SBD\_fas.txt“ (formát Pearson/FASTA); dodržte vstupné poradie sekvencií (input order).
- (9) V zrovnaných SBD sekvenciách, t.j. v súbore „SBD\_aln.txt“ uloženého ako dokument súboru „SBD\_aln.doc“, žltým podsvietením farebne zvýraznite charakteristické konzervované zvyšky (ak sú prítomné): ~30 aa ... lg-W ... ~15 aa ... p-W ... ~15 aa ... fKf ... ~10 aa ... W----n ... ~15 aa (C-koniec zrovnania).
- (10) Na EBI serveri v rámci programu Simple-Phylogeny vypočítajte dva evolučné stromy pre SBD – s uvažovaním, resp. s ignorovaním medzier v sekvenciách „SBD\_off.txt“ a „SBD\_on.txt“. Evolučné stromy zobrazte v programe iTOL („circular“), exportujte ako PNG súbory a vložte pod zrovnanie do súboru „SBD\_aln.doc“.
- (11) Pre zrovnané SBD sekvencie (alignment) zistite konsenzuálnu dĺžku (CL), vypočítajte sekvenčnú identitu (SI) a podobnosť (SS) a výsledky spolu s diskusiou celej práce slovne zapíšte.
- (12) V priečinku „BLAST\_CBM20“ budú uložené nasledovné súbory:
  - (a) celý html súbor CGTázy z databázy UniProt („CGTase.htm“);
  - (b) Vaše výsledky z BLASTu (html súbor: „SBD\_BLAST.htm“; Max. target sequences: 250);
  - (c) vyplnená tab. 7.9 s 30 zdrojmi SBD identifikovanými v BLASte (DOC súbor: „SBD\_Tabulka.doc“);
  - (d) vstupný súbor s 30 SBD sekvenciami (textový súbor: „SBD.txt“);
  - (e) zrovnania SBD sekvencií (súbory: „SBD\_aln.txt“ a „SBD\_fas.txt“);
  - (f) zrovnanie vo formáte ALN („SBD\_aln.doc“) s farebne zvýraznenými konzervovanými zvyškami (podľa bodu 9), vloženými obrázkami evolučných stromov (podľa bodu 10) a pod tým hodnoty CL, SI a SS a diskusia evolučných stromov;
  - (g) vypočítané súbory (nie obrázky) evolučných stromov („SBD\_off.txt“ a „SBD\_on.txt“).

**Tabuľka 7.9.** Zoznam sekvencii škrob-viažúcich domén z rodiny CBM20 (prípadne CBM48).

<b>Č.</b>	<b>Skratka</b>	<b>Enzým/proteín</b>	<b>Zdroj</b>	<b>UniProt/GenBank</b>	<b>E-hodnota</b>	<b>Skóre</b>	<b>Dĺžka</b>	<b>SBD</b>
1	Bacci_CGT	CGTáza	<i>Bacillus circulans</i>	P30920			718	613-718
2								
3								
4								
5								
6								
7								
8								
9								
10								
11								
12								
13								
14								
15								
16								
17								
18								
19								
20								
21								
22								
23								
24								
25								
26								
27								
28								
29								
30								

## 7.10. Predikcia a porovnávanie terciárnej štruktúry proteínov

### Teória

Proteín:

- $\alpha$ -amyláza z *Haloarcula hispanica* z rodiny glykozidových hydroláz GH13;
- UniProt Acc. No.: Q4A3E0;
- dĺžka: 433 aminokyselinových zvyškov;
- štruktúra je zložená z troch domén: (i) doména A – katalytická TIM-barelová doména: časť A1 – Met1-Asn136 a časť A2 – Ala193-Ser355; (ii) doména B – v pozícii medzi vláknom  $\beta$ 3 a helixom  $\alpha$ 3: His137-Ser192; a (iii) doména C – antiparalelná  $\beta$ -sendvičová C-terminálna doména: Gly356-Glu433;
- potenciálne katalytické zvyšky: Asp217 (katalytický nukleofil), Glu245 (donor protónov) a Asp308 (stabilizátor prechodového stavu).

### Zadanie:

- (1) Vytvorte si priečinok „Haloarcula“.
- (2) Pre sekvenciu  $\alpha$ -amylázy z *Haloarcula hispanica* vykonajte predikciu terciárnej štruktúry metódou rozpoznania potenciálnej terciárnej štruktúry (tzv. „fold recognition“) na serveri Phyre2: [www.sbg.bio.ic.ac.uk/phyre2/](http://www.sbg.bio.ic.ac.uk/phyre2/). Všetkých 20 získaných modelov uložte ako PDB súbory „AAMY\_Halhi\_xxxx\_1.pdb“, „AAMY\_Halhi\_xxxx\_2.pdb“, ..., „AAMY\_Halhi\_xxxx\_20.pdb“; kde „xxxx“ je PDB kód terciárnej štruktúry templátu a čísla 1-20 sú poradové čísla jednotlivých modelov.
- (3) Vyberte si 7 modelov (nie prvých 7 modelov v poradí) terciárnej štruktúry  $\alpha$ -amylázy z *Haloarcula hispanica* a zobrazte ich v programe WebLabViewerLite pri vypnutí atómov ako „solid ribbon“, pričom jednotlivé domény farbite nasledovne: doména A – modrá, doména B – červená a doména C – zelená. Potom zobrazte katalytické aminokyselinové zvyšky ako „stick“ a farbite ako „element“. Všetkých 7 zobrazených modelov sa pokúste kvôli vizuálnemu porovnaniu naorientovať podobne a uložte ako „\*.msv“ aj „\*.gif“, resp. „\*.jpg“ súbory.
- (4) Máte k dispozícii, resp. získajte:
  - (a) koordináty 3 modelov terciárnej štruktúry  $\alpha$ -amylázy z *Haloarcula hispanica*, získané metódou homologického modelovania (Phyre2 server); tieto súbory označte: „AAMY\_Phyre\_1HVX.pdb“, „AAMY\_Phyre\_3BLP.pdb“ a „AAMY\_Phyre\_1MWO.pdb“;
  - (b) koordináty 3 experimentálne určených terciárnych štruktúr reálnych  $\alpha$ -amyláz z *Bacillus stearothermophilus* (PDB: 1HVX), z *Homo sapiens* (PDB: 3BLP) a *Pyrococcus woesei* (PDB: 1MWO); tieto súbory označte: „AAMY\_1HVX.pdb“, „AAMY\_3BLP.pdb“ a „AAMY\_1MWO.pdb“.

- (5) Vytvorte si 9 priečinkov a v nich 9 ZIP súborov obsahujúcich všetky príslušné dvojice štruktúr modelu  $\alpha$ -amylázy z *H. hispanica* a reálnej štruktúry podľa nasledovného členenia:
- 1: AAMY\_Phyre\_1HVX.pdb a AAMY\_1HVX.pdb;
  - 2: AAMY\_Phyre\_1HVX.pdb a AAMY\_3BLP.pdb;
  - 3: AAMY\_Phyre\_1HVX.pdb a AAMY\_1MWO.pdb;
  - 4: AAMY\_Phyre\_3BLP.pdb a AAMY\_1HVX.pdb;
  - 5: AAMY\_Phyre\_3BLP.pdb a AAMY\_3BLP.pdb;
  - 6: AAMY\_Phyre\_3BLP.pdb a AAMY\_1MWO.pdb;
  - 7: AAMY\_Phyre\_1MWO.pdb a AAMY\_1HVX.pdb
  - 8: AAMY\_Phyre\_1MWO.pdb a AAMY\_3BLP.pdb
  - 9: AAMY\_Phyre\_1MWO.pdb a AAMY\_1MWO.pdb.
- (6) Na serveri MultiProt: <http://bioinfo3d.cs.tau.ac.il/MultiProt/> podľa požiadaviek („upload a ZIP file of PDB structures“) spravte postupne vzájomné preloženia všetkých 9 dvojíc štruktúr a poskytnuté údaje zapísť do tab. 7.10 – hodnotu RMSD a počet korešpondujúcich Ca atómov (v zátvorke):

**Tabuľka 7.10.** Superpozície modelov  $\alpha$ -amylázy z *H. hispanica* s templátkmi.

	AAMY_Phyre_1HVX.pdb	AAMY_Phyre_3BLP.pdb	AAMY_Phyre_1MWO.pdb
AAMY_1HVX.pdb			
AAMY_3BLP.pdb			
AAMY_1MWO.pdb			

- (7) Všetkých 9 preložených štruktúr (PDB alignment) spolu s príslušným zrovnaním (Alignment size) a výsledkami uložte s názvom ZIP súboru (napr. „1\_overlap.pdb“, „1\_alignment.htm“ a „1\_vysledky.htm“ – ako kompletnej web-stránku; atď.). Zrovnania vizuálne prezrite s ohľadom na funkčne dôležité zvyšky (udané nižšie) a preklady zobrazte v programe WebLabViewerLite pri vypnutí atómov ako „solid ribbon“ a farbite vždy jednu štruktúru tyrkysovou a druhú oranžovou farbou. Potom zobrazte katalyticke a funkčne dôležité aminokyselinové zvyšky – ako „stick“: (i)  $\alpha$ -amyláza z *Haloarcula hispanica* – His137, Arg215, Asp217, Glu245, His307 a Asp308; (ii)  $\alpha$ -amyláza z *Bacillus stearothermophilus* – His106, Arg232, Asp234, Glu264, His330 a Asp331; (iii)  $\alpha$ -amyláza z *Homo sapiens* – His101, Arg195, Asp197, Glu233, His299 a Asp300; a (iv)  $\alpha$ -amyláza z *Pyrococcus woesei* – His111, Arg196, Asp198, Glu222, His288 a Asp289; a farbite vždy modrou v tyrkysovej štruktúre a fialovou v oranžovej štruktúre. Všetky zobrazenia uložte ako príslušné „\*.msv“ a „\*.gif“, resp. „\*.jpg“ súbory.

## **7.11. Projekt kompletnej bioinformatickej analýzy proteínu/enzýmu**

„Acc\_No“ predstavuje prístupové číslo (accession No.) ľubovoľného proteínu/enzýmu z databázy UniProt.

- (1) Uložte kompletný súbor pre Váš proteín/enzým z databázy UniProt (<http://www.uniprot.org/>) ako HTML súbor: „Acc\_No.html“ (kompletná web-stránka).
- (2) Identifikujte tento proteín/enzým v databáze GenBank (<http://www.ncbi.nlm.nih.gov/genbank/>) a uložte kompletný súbor pre jeho gén („genomic DNA“), ako aj preklad („translation“; „protein\_id“) ako HTML súbory: „GenBank\_Acc\_No.html“ a „GenPept\_Acc\_No.html“ (kompletné web-stránky). Nájdite v literatúre publikáciu, v ktorej bola popísaná sekvencia Vášho proteínu/enzýmu a súbor uložte ako PDF súbor: „Acc\_No.pdf“.
- (3) So sekvenciou Vášho proteínu/enzýmu vykonajte štandardný proteínový BLAST (Max. target sequences: 500; <http://blast.ncbi.nlm.nih.gov/Blast.cgi>) a výsledky uložte ako HTML súbor: „Acc\_No\_BLAST\_500.html“ (kompletná web-stránka). Vo výsledkoch BLASTu identifikujte ďalších 39 príbuzných proteínov/enzýmov do tabuľky (názov: „Tabuľka študovaných proteínov/enzýmov“; uložená ako DOC súbor: „Acc\_No\_Table.doc“), v ktorej budú nasledovné stĺpce: (i) „Číslo“; (ii) „Zdroj“ (proteínu/enzýmu); (iii) „Skratka“; (iv) „UniProt“ (accession No.); (v) „GenBank“ (accession No.); (vi) „Dĺžka“ (proteínu/enzýmu); a (vii) „Skóre“ (z BLASTu). To znamená, že Váš proteín/enzým bude č. 1 v tabuľke a pod ním bude ďalších 39 proteínov/enzýmov usporiadaných podľa klesajúceho skóre z BLASTu. Pokiaľ sa to bude dať, pokúsite sa identifikovať tých 39 príbuzných proteínov/enzýmov z čo najširšieho spektra organizmov (*Archaea, Bacteria, Eucarya*).
- (4) Sekvencie všetkých 40 proteínov/enzýmov porovnajte, to znamená, že: (i) pripravíte vstupný súbor („Acc\_No\_input.txt“); (ii) na EBI serveri (<http://www.ebi.ac.uk/>) sekvencie zrovnaťe v programe Clustal-Omega – získate dva súbory: „Acc\_No\_input\_aln.txt“ a „Acc\_No\_input\_fas.txt“ – zrovnania vo formáte „alignment“ (Clustal with character counts) a „Pearson/FASTA“; (iii) na EBI serveri v rámci programu Simple-Phylogeny vypočítate dva evolučné stromy pre študované proteíny/enzýmy – s uvažovaním medzier v sekvenciach („Acc\_No\_input\_off.txt“) a s ich ignorovaním („Acc\_No\_input\_on.txt“); (iv) zrovnanie vo formáte „alignment“ uložte ako DOC („Acc\_No\_input\_aln.doc“) a v ňom zvýraznite žltým podfarbením funkčne dôležité zvyšky (napr. katalyticke zvyšky, prípadne zvyšky aktívneho miesta) identifikované buď z databázy UniProt alebo z literatúry, prípadne z výsledkov BLASTu, ďalej pod zrovnaním budú zapísané hodnoty konsenzuálnej dĺžky (CL), sekvenčnej identity (SI) a sekvenčnej podobnosti (SS), vložené obrázky evolučných stromov (napr. ako PNG)

získané v programe iTOL (interactive Tree of Life; <https://itol.embl.de/>) a ich slovná diskusia.

- (5) Pre sekvenciu Vášho proteínu/enzýmu vykonajte predikciu sekundárnej štruktúry metódou GOR-IV (na serveri <http://npsa-prabi.ibcp.fr/>). Kompletné výsledky z predikcie serveru uložte ako HTML súbor: „Acc\_No\_2D\_GOR4\_results.html“ (kompletná web-stránka). Pravidelné elementy získanej predpovedanej sekundárnej štruktúry (t.j. iba H a E, t.j. α-helix a β-list) zapísťe pod aminokyselinovú sekvenciu a uložte v riadkoch po 60 pozícii do textového súboru: „Acc\_No\_2D\_GOR4.txt“ (1. riadok – poradové číslo v sekvencii: 10, 20, 30, atď; 2. riadok – aminokyselinová sekvencia; a 3. riadok – predikcia H, resp. E – pod príslušným zvyškom).
- (6) Pre sekvenciu Vášho proteínu/enzýmu vykonajte predikciu terciárnej štruktúry metódou rozpoznania terciárnej štruktúry (tzv. „fold recognition“) na serveri Phyre2: <http://www.sbg.bio.ic.ac.uk/phyre2/>. Po prezretí výsledkov vyberte jeden najlepší model a uložte ho ako PDB súbor: „Acc\_No\_3D\_Phyre2\_template.pdb“ (namiesto „template“ bude vždy v názve súboru PDB-kód templátovej terciárnej štruktúry, podľa ktorej bol model Vášho proteínu/enzýmu získaný). Váš výber modelu z výsledkov predikcie zdôvodnite (podľa „alignment coverage“, „confidence“, „% i.d.“ a „template information“) v textovom súbore: „Acc\_No\_3D\_Phyre2\_template.txt“, kde bude aj informácia, koľko templátov bolo identifikovaných a koľko modelov bolo skutočne pripravených, ako aj www adresa, kde sa na Phyre2 serveri dočasne nachádzajú kompletné výsledky predikcie Vášho proteínu/enzýmu. Z databázy PDB (<http://www.rcsb.org/>) získajte koordináty terciárnej štruktúry templátu a uložte ako PDB súbor: „Acc\_No\_PDB\_template.pdb“. Obe štruktúry, t.j. aj model Vášho proteínu/enzýmu, aj templát zobrazte v programe WebLabViewerLite ako pohľad na kompletnú terciárnu štruktúru pri zobrazení „solid ribbon“ (pri súčasnom vypnutí atómov) a funkčne dôležité aminokyselinové zvyšky (napr. katalyticke, resp. zvyšky aktívneho miesta) zobrazte ako „stick“ a farbite ako „element“ – súbory „\*.msv“: (i) Váš model – „Acc\_No\_3D\_Phyre2\_template.msv“; a (ii) templát – „Acc\_No\_PDB\_template.msv“.
- (7) Pripravte si ZIP súbor „Acc\_No\_MultiProt.zip“ so štruktúrou Vášho modelu a jeho templátu a na serveri MultiProt (<http://bioinfo3d.cs.tau.ac.il/MultiProt/>) podľa požiadaviek servera spravte vzájomnú superpoziciu oboch štruktúr. Poskytnuté údaje – hodnotu RMSD a počet korešpondujúcich Ca atómov (v závorke) – zapísťe do textového súboru „Acc\_No\_MultiProt\_results.txt“. Získané výsledky uložte nasledovne: (i) stránku s výsledkami ako „Acc\_No\_MultiProt\_results.html“ (kompletná web-stránka); (ii) zrovnanie sekvencií založené na štruktúre – „alignment size“ ako „Acc\_No\_MultiProt\_alignment.html“ (kompletná web-stránka); a (iii) preložené štruktúry – „PDB alignment“ ako PDB súbor „Acc\_No\_Multiprot\_overlap.pdb“. Obe preložené štruktúry zobrazte v programe WebLabViewerLite ako: (i) celkový pohľad na kompletnú

terciárnu štruktúru pri zobrazení „solid ribbon“ (pri súčasnom vypnutí atómov) s funkčne dôležitými aminokyselinovými zvyškami (napr. katalytickými, resp. zvyškami aktívneho miesta) ako „stick“ (súbor „Acc\_No\_Multiprot\_overlap.msv“); a (ii) detailný pohľad (priblíženie) na oblasť s funkčne dôležitými zvyškami v zobrazení proteínu/enzýmu ako „line ribbon“ a selektovanými zvyškami ako „stick“ (súbor „Acc\_No\_Multiprot\_overlap\_detail.msv“). Model Vášho proteínu/enzýmu farbite tyrkysovou farbou a štruktúru templátu farbite oranžovou farbou, pričom funkčne dôležité zvyšky farbite modrou farbou v modeli a červenou farbou v templáte.

- (8) Výsledky tohto projektu budú pripravené ako ZIP, ktorý bude obsahovať tieto súbory:
- (a) Acc\_No.html
  - (b) GenBank\_Acc\_No.html
  - (c) GenPept\_Acc\_No.html
  - (d) Acc\_No.pdf
  - (e) Acc\_No\_BLAST\_500.html
  - (f) Acc\_No\_Table.doc
  - (g) Acc\_No\_input.txt
  - (h) Acc\_No\_input\_aln.txt
  - (i) Acc\_No\_input\_fas.txt
  - (j) Acc\_No\_input\_off.txt
  - (k) Acc\_No\_input\_on.txt
  - (l) Acc\_No\_input\_aln.doc
  - (m) Acc\_No\_2D\_GOR4\_results.html
  - (n) Acc\_No\_2D\_GOR4.txt
  - (o) Acc\_No\_3D\_Phyre2\_template.pdb
  - (p) Acc\_No\_3D\_Phyre2\_template.txt
  - (q) Acc\_No\_PDB\_template.pdb
  - (r) Acc\_No\_3D\_Phyre2\_template.msv
  - (s) Acc\_No\_PDB\_template.msv
  - (t) Acc\_No\_MultiProt.zip
  - (u) Acc\_No\_MultiProt\_results.txt
  - (v) Acc\_No\_MultiProt\_results.html
  - (w) Acc\_No\_MultiProt\_alignment.html
  - (x) Acc\_No\_Multiprot\_overlap.pdb
  - (y) Acc\_No\_Multiprot\_overlap.msv
  - (z) Acc\_No\_Multiprot\_overlap\_detail.msv

## Použitá a odporúčaná literatúra

- Altschul S.F., Gish W., Miller W., Myers E.W. & Lipman D.J. 1990. Basic local alignment search tool. *J. Mol. Biol.* **215**: 403–410. [https://doi.org/10.1016/S0022-2836\(05\)80360-2](https://doi.org/10.1016/S0022-2836(05)80360-2)
- Altschul S.F. & Koonin E.V. 1998. Iterated profile searches with PSI-BLAST – a tool for discovery in protein databases. *Trends Biochem. Sci.* **23**: 444–447. [https://doi.org/10.1016/s0968-0004\(98\)01298-5](https://doi.org/10.1016/s0968-0004(98)01298-5)
- Altschul S.F., Madden T.L., Schäffer A.A., Zhang J., Zhang Z., Miller W. & Lipman D.J. 1997. Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Res.* **25**: 3389–3402. <https://doi.org/10.1093/nar/25.17.3389>
- Amid C., Alako B.T.F., Balavenkataraman Kadhirvelu V., Burdett T., Burgin J., Fan J., Harrison P.W., Holt S., Hussein A., Ivanov E., Jayathilaka S., Kay S., Keane T., Leinonen R., Liu X., Martinez-Villacorta J., Milano A., Pakseresht A., Rahman N., Rajan J., Reddy K., Richards E., Smirnov D., Sokolov A., Vijayaraja S. & Cochrane G. 2020. The European Nucleotide Archive in 2019. *Nucleic Acids Res.* **48 (Database Issue 1)**: D70–D76. <https://doi.org/10.1093/nar/gkz1063>
- Armstrong D.R., Berrisford J.M., Conroy M.J., Gutmanas A., Anyango S., Choudhary P., Clark A.R., Dana J.M., Deshpande M., Dunlop R., Gane P., Gáborová R., Gupta D., Haslam P., Koča J., Mak L., Mir S., Mukhopadhyay A., Nadzirin N., Nair S., Paysan-Lafosse T., Pravda L., Sehnal D., Salih O., Smart O., Tolchard J., Varadi M., Svobodova-Váreková R., Zaki H., Kleywegt G.J. & Velankar S. 2020. PDBe: improved findability of macromolecular structure data in the PDB. *Nucleic Acids Res.* **48 (Database Issue 1)**: D335–D343. <https://doi.org/10.1093/nar/gkz990>
- Blattner F.R., Plunkett G. 3rd, Bloch C.A., Perna N.T., Burland V., Riley M., Collado-Vides J., Glasner J.D., Rode C.K., Mayhew G.F., Gregor J., Davis N.W., Kirkpatrick H.A., Goeden M.A., Rose D.J., Mau B. & Shao Y. 1997. The complete genome sequence of *Escherichia coli* K-12. *Science* **277**: 1453–1462. <https://doi.org/10.1126/science.277.5331.1453>
- Boratyn G.M., Schäffer A.A., Agarwala R., Altschul S.F., Lipman D.J. & Madden T.L. 2012. Domain enhanced lookup time accelerated BLAST. *Biol. Direct* **7**: 12. <https://doi.org/10.1186/1745-6150-7-12>
- Bult C.J., White O., Olsen G.J., Zhou L., Fleischmann R.D., Sutton G.G., Blake J.A., FitzGerald L.M., Clayton R.A., Gocayne J.D., Kerlavage A.R., Dougherty B.A., Tomb J.F., Adams M.D., Reich C.I., Overbeek R., Kirkness E.F., Weinstock K.G., Merrick J.M., Glodek A., Scott J.L., Geoghegan N.S. & Venter J.C. 1996. Complete genome sequence of the methanogenic archaeon, *Methanococcus jannaschii*. *Science* **273**: 1058–1073. <https://doi.org/10.1126/science.273.5278.1058>
- Callebaut I., Labesse G., Durand P., Poupon A., Canard L., Chomilier J., Henrissat B. & Mornon J.P. 1997. Deciphering protein sequence information through hydrophobic cluster analysis (HCA): current status and perspectives. *Cell. Mol Life Sci.* **53**: 621–645. <https://doi.org/10.1007/s000180050082>
- Cole S.T., Brosch R., Parkhill J., Garnier T., Churcher C., Harris D., Gordon S.V., Eiglmeier K., Gas S., Barry C.E. 3rd, Tekaia F., Badcock K., Basham D., Brown D., Chillingworth T., Connor R., Davies R., Devlin K., Feltwell T., Gentles S., Hamlin N., Holroyd S., Hornsby T., Jagels K., Krogh A., McLean J., Moule S., Murphy L., Oliver K., Osborne J., Quail M.A., Rajandream M.A., Rogers J., Rutter S., Seeger K., Skelton J., Squares R., Squares S., Sulston J.E., Taylor K., Whitehead S. & Barrell B.G. 1998. Deciphering the biology of *Mycobacterium tuberculosis* from the complete genome sequence. *Nature* **393**: 537–544. <https://doi.org/10.1038/31159>

Cook C.E., Stroe O., Cochrane G., Birney E. & Apweiler R. 2020. The European Bioinformatics Institute in 2020: building a global infrastructure of interconnected data resources for the life sciences. *Nucleic Acids Res.* **48 (Database Issue 1):** D17–D23. <https://doi.org/10.1093/nar/gkz1033>

Fleischmann R.D., Adams M.D., White O., Clayton R.A., Kirkness E.F., Kerlavage A.R., Bult C.J., Tomb J.F., Dougherty B.A., Merrick J.M., McKenney K., Sutton G.G., FitzHugh W., Fields C.A., Gocayne J.D., Scott J.D., Shirley R., Liu L.I., Glodek A., Kelley J.M., Weidman J.F., Phillips C.A., Spriggs T., Hedblom E., Cotton M.D., Utterback T., Hanna M.C., Nguyen D.T., Saudek D.M., Brandon R.C., Fine L.D., Fritchman J.L., Fuhrmann J.L., Geoghagen N.S., Gnehm C.L., McDonald L.A., Small K.V., Fraser C.M., Smith H.O. & Venter J.C. 1995. Whole-genome random sequencing and assembly of *Haemophilus influenzae* Rd. *Science* **269:** 496–512. <https://doi.org/10.1126/science.7542800>

Fraser C.M., Casjens S., Huang W.M., Sutton G.G., Clayton R., Lathigra R., White O., Ketchum K.A., Dodson R., Hickey E.K., Gwinn M., Dougherty B., Tomb J.F., Fleischmann R.D., Richardson D., Peterson J., Kerlavage A.R., Quackenbush J., Salzberg S., Hanson M., van Vugt R., Palmer N., Adams M.D., Gocayne J., Weidman J., Utterback T., Watthey L., McDonald L., Artiach P., Bowman C., Garland S., Fuji C., Cotton M.D., Horst K., Roberts K., Hatch B., Smith H.O. & Venter J.C. 1997. Genomic sequence of a Lyme disease spirochaete, *Borrelia burgdorferi*. *Nature* **390:** 580–586. <https://doi.org/10.1038/37551>

Fraser C.M., Gocayne J.D., White O., Adams M.D., Clayton R.A., Fleischmann R.D., Bult C.J., Kerlavage A.R., Sutton G., Kelley J.M., Fritchman R.D., Weidman J.F., Small K.V., Sandusky M., Fuhrmann J., Nguyen D., Utterback T.R., Saudek D.M., Phillips C.A., Merrick J.M., Tomb J.F., Dougherty B.A., Bott K.F., Hu P.C., Lucier T.S., Peterson S.N., Smith H.O., Hutchison C.A. 3rd & Venter J.C. 1995. The minimal gene complement of *Mycoplasma genitalium*. *Science* **270:** 397–403. <https://doi.org/10.1126/science.270.5235.397>

Fraser C.M., Norris S.J., Weinstock G.M., White O., Sutton G.G., Dodson R., Gwinn M., Hickey E.K., Clayton R., Ketchum K.A., Sodergren E., Hardham J.M., McLeod M.P., Salzberg S., Peterson J., Khalak H., Richardson D., Howell J.K., Chidambaram M., Utterback T., McDonald L., Artiach P., Bowman C., Cotton M.D., Fujii C., Garland S., Hatch B., Horst K., Roberts K., Sandusky M., Weidman J., Smith H.O. & Venter J.C. 1998. Complete genome sequence of *Treponema pallidum*, the syphilis spirochete. *Science* **281:** 375–388. <https://doi.org/10.1126/science.281.5375.375>

Gaboriaud C, Bissery V, Benchetrit T, Mornon JP. 1987. Hydrophobic cluster analysis: an efficient new way to compare and analyse amino acid sequences. *FEBS Lett.* **224:** 149–155. [https://doi.org/10.1016/0014-5793\(87\)80439-8](https://doi.org/10.1016/0014-5793(87)80439-8)

Heidelberg J.F., Eisen J.A., Nelson W.C., Clayton R.A., Gwinn M.L., Dodson R.J., Haft D.H., Hickey E.K., Peterson J.D., Umayam L., Gill S.R., Nelson K.E., Read T.D., Tettelin H., Richardson D., Ermolaeva M.D., Vamathevan J., Bass S., Qin H., Dragoi I., Sellers P., McDonald L., Utterback T., Fleishmann R.D., Nierman W.C., White O., Salzberg S.L., Smith H.O., Colwell R.R., Mekalanos J.J., Venter J.C. & Fraser C.M. 2000. DNA sequence of both chromosomes of the cholera pathogen *Vibrio cholerae*. *Nature* **406:** 477–483. <https://doi.org/10.1038/35020000>

Heidelberg J.F., Paulsen I.T., Nelson K.E., Gaidos E.J., Nelson W.C., Read T.D., Eisen J.A., Seshadri R., Ward N., Methe B., Clayton R.A., Meyer T., Tsapin A., Scott J., Beanan M., Brinkac L., Daugherty S., DeBoy R.T., Dodson R.J., Durkin A.S., Haft D.H., Kolonay J.F., Madupu R., Peterson J.D., Umayam L.A., White O., Wolf A.M., Vamathevan J., Weidman J., Impraim M., Lee K., Berry K., Lee C., Mueller J., Khouri H., Gill J., Utterback T.R., McDonald L.A., Feldblyum T.V., Smith H.O., Venter J.C., Nealson K.H. & Fraser C.M. 2002. Genome sequence of the dissimilatory metal ion-reducing bacterium *Shewanella oneidensis*. *Nat. Biotechnol.* **20:** 1118–1123. <https://doi.org/10.1038/nbt749>

International Human Genome Sequencing Consortium. 2001. Initial sequencing and analysis of the human genome. *Nature* **409**: 860–921.  
<https://doi.org/10.1038/35057062>

Istrail S., Sutton G.G., Florea L., Halpern A.L., Mobarry C.M., Lippert R., Walenz B., Shatkay H., Dew I., Miller J.R., Flanigan M.J., Edwards N.J., Bolanos R., Fasulo D., Halldorsson B.V., Hannenhalli S., Turner R., Yooseph S., Lu F., Nusskern D.R., Shue B.C., Zheng X.H., Zhong F., Delcher A.L., Huson D.H., Kravitz S.A., Mouchard L., Reinert K., Remington K.A., Clark A.G., Waterman M.S., Eichler E.E., Adams M.D., Hunkapiller M.W., Myers E.W. & Venter J.C. 2004. Whole-genome shotgun assembly and comparison of human genome assemblies. *Proc. Natl. Acad. Sci. USA* **101**: 1916–1921. <https://doi.org/10.1073/pnas.0307971100>

Janecek S. 2002. A motif of a microbial starch-binding domain found in human genethonin. *Bioinformatics* **18**: 1534–1537. <https://doi.org/10.1093/bioinformatics/18.11.1534>

Janecek S. 2014. *Proteínový dizajn*. Učebný text. Univerzita sv. Cyrila a Metoda v Trnave, Trnava. ISBN 978-80-8105-594-2.  
[http://fpv.ucm.sk/images/ucebne\\_texty/Proteinovy\\_dizajn.pdf](http://fpv.ucm.sk/images/ucebne_texty/Proteinovy_dizajn.pdf)

Janecek S., Marecek F., MacGregor E.A. & Svensson B. 2019. Starch-binding domains as CBM families – history, occurrence, structure, function and evolution. *Biotechnol. Adv.* **37**: 107451. <https://doi.org/10.1016/j.biotechadv.2019.107451>

Janecek S., Svensson B. & Henrissat B. 1997. Domain evolution in the α-amylase family. *J. Mol. Evol.* **45**: 322–331. <https://doi.org/10.1007/pl00006236>

Janecek S., Svensson B. & MacGregor E.A. 2003. Relation between domain evolution, specificity, and taxonomy of the α-amylase family members containing a C-terminal starch-binding domain. *Eur. J. Biochem.* **270**: 635–645.  
<https://doi.org/10.1046/j.1432-1033.2003.03404.x>

Janecek S., Svensson B. & MacGregor E.A. 2014. α-Amylase – an enzyme specificity found in various families of glycoside hydrolases. *Cell. Mol. Life Sci.* **71**: 1149–1170.  
<https://doi.org/10.1007/s00018-013-1388-z>

Janecek S. & Zamocka B. 2020. A new GH13 subfamily represented by the α-amylase from the halophilic archaeon *Haloarcula hispanica*. *Extremophiles* **24**: 207–217.  
<https://doi.org/10.1007/s00792-019-01147-y>

Kelley L.A., Mezulis S., Yates C.M., Wass M.N. & Sternberg M.J. 2015. The Phyre2 web portal for protein modeling, prediction and analysis. *Nat. Protoc.* **10**: 845–858.  
<https://doi.org/10.1038/nprot.2015.053>

Kelley L.A. & Sternberg M.J. 2009. Protein structure prediction on the Web: a case study using the Phyre server. *Nat. Protoc.* **4**: 363–371.  
<https://doi.org/10.1038/nprot.2009.2>

Klein C. & Schulz G.E. 1991. Structure of cyclodextrin glycosyltransferase refined at 2.0 Å resolution. *J. Mol. Biol.* **217**: 737–750. [https://doi.org/10.1016/0022-2836\(91\)90530-j](https://doi.org/10.1016/0022-2836(91)90530-j)

Klenk H.P., Clayton R.A., Tomb J.F., White O., Nelson K.E., Ketchum K.A., Dodson R.J., Gwinn M., Hickey E.K., Peterson J.D., Richardson D.L., Kerlavage A.R., Graham D.E., Kyripides N.C., Fleischmann R.D., Quackenbush J., Lee N.H., Sutton G.G., Gill S., Kirkness E.F., Dougherty B.A., McKenney K., Adams M.D., Loftus B., Peterson S., Reich C.I., McNeil L.K., Badger J.H., Glodek A., Zhou L., Overbeek R., Gocayne J.D., Weidman J.F., McDonald L., Utterback T., Cotton M.D., Spriggs T., Artiach P., Kaine B.P., Sykes S.M., Sadow P.W., D'Andrea K.P., Bowman C., Fujii C., Garland S.A., Mason T.M., Olsen G.J., Fraser C.M., Smith H.O., Woese C.R. & Venter J.C. 1997. The complete genome sequence of the hyperthermophilic, sulphate-reducing archaeon *Archaeoglobus fulgidus*. *Nature* **390**: 364–370. <https://doi.org/10.1038/37052>

Korenberg J.R., Chen X.N., Adams M.D. & Venter J.C. 1995. Toward a cDNA map of the human genome. *Genomics* **29**: 364–370. <https://doi.org/10.1006/geno.1995.9993>

Kunst F., Ogasawara N., Moszer I., Albertini A.M., Alloni G., Azevedo V., Bertero M.G., Bessieres P., Bolotin A., Borchert S., Borriss R., Boursier L., Brans A., Braun M., Brignell S.C., Bron S., Brouillet S., Bruschi C.V., Caldwell B., Capuano V., Carter N.M., Choi S.K., Cordani J.J., Connerton I.F., Cummings N.J., Daniel R.A., Denziot F., Devine K.M., Düsterhoff A., Ehrlich S.D., Emmerson P.T., Entian K.D., Errington J., Fabret C., Ferrari E., Foulger D., Fritz C., Fujita M., Fujita Y., Fuma S., Galizzi A., Galleron N., Ghim S.Y., Glaser P., Goffeau A., Golightly E.J., Grandi G., Guiseppi G., Guy B.J., Haga K., Haiech J., Harwood C.R., Henaut A., Hilbert H., Holsappel S., Hosono S., Hullo M.F., Itaya M., Jones L., Joris B., Karamata D., Kasahara Y., Klaerr-Blanchard M., Klein C., Kobayashi Y., Koetter P., Koningstein G., Krogh S., Kumano M., Kurita K., Lapidus A., Lardinois S., Lauber J., Lazarevic V., Lee S.M., Levine A., Liu H., Masuda S., Mauël C., Medigue C., Medina N., Mellado R.P., Mizuno M., Moestl D., Nakai S., Noback M., Noone D., O'Reilly M., Ogawa K., Ogiwara A., Oudega B., Park S.H., Parro V., Pohl T.M., Portelle D., Porwollik S., Prescott A.M., Presecan E., Pujic P., Purnelle B., Rapoport G., Rey M., Reynolds S., Rieger M., Rivolta C., Rocha E., Roche B., Rose M., Sadaie Y., Sato T., Scanlan E., Schleich S., Schroeter R., Scoffone F., Sekiguchi J., Sekowska A., Seror S.J., Serror P., Shin B.S., Soldo B., Sorokin A., Tacconi E., Takagi T., Takahashi H., Takemaru K., Takeuchi M., Tamakoshi A., Tanaka T., Terpstra P., Togoni A., Tosato V., Uchiyama S., Vandebol M., Vannier F., Vassarotti A., Viari A., Wambutt R., Wedler H., Weitzenegger T., Winters P., Wipat A., Yamamoto H., Yamane K., Yasumoto K., Yata K., Yoshida K., Yoshikawa H.F., Zumstein E., Yoshikawa H. & Danchin A. 1997. The complete genome sequence of the gram-positive bacterium *Bacillus subtilis*. *Nature* **390**: 249–256. <https://doi.org/10.1038/36786>

Lawson C.L., van Montfort R., Strokopytov B., Rozeboom H.J., Kalk K.H., de Vries G.E., Penninga D., Dijkhuizen L. & Dijkstra B.W. 1994. Nucleotide sequence and X-ray structure of cyclodextrin glycosyltransferase from *Bacillus circulans* strain 251 in a maltose-dependent crystal form. *J. Mol. Biol.* **236**: 590–600.  
<https://doi.org/10.1006/jmbi.1994.1168>

Lemesle-Varloot L., Henrissat B., Gaboriaud C., Bissery V., Morgat A. & Mornon J.P. 1990. Hydrophobic cluster analysis: procedures to derive structural and functional information from 2-D-representation of protein sequences. *Biochimie* **72**: 555–774.  
[https://doi.org/10.1016/0300-9084\(90\)90120-6](https://doi.org/10.1016/0300-9084(90)90120-6)

Lesk A.M. 2001. *Introduction to Protein Architecture*. Oxford University Press, Oxford, ISBN 0198504748.

Lesk A.M. 2002. *Introduction to Bioinformatics*. Oxford University Press, Oxford. ISBN 0199251967.

Lesk A.M. 2004. *Introduction to Protein Science*. Oxford University Press, Oxford, ISBN 9780199265114.

Letunic I. & Bork P. 2007. Interactive Tree Of Life (iTOL): an online tool for phylogenetic tree display and annotation. *Bioinformatics* **23**: 127–128.  
<https://doi.org/10.1093/bioinformatics/btl529>

Majzlova K., Pukajova Z. & Janecek S. 2013. Tracing the evolution of the α-amylase subfamily GH13\_36 covering the amyloytic enzymes intermediate between oligo-1,6-glucosidases and neopullulanases. *Carbohydr. Res.* **367**: 48–57.  
<https://doi.org/10.1016/j.carres.2012.11.022>

Markovic O. & Janecek S. 2001. Pectin degrading glycoside hydrolases of family 28: sequence-structural features, specificities and evolution. *Protein Eng.* **14**: 615–631.  
<https://doi.org/10.1093/protein/14.9.615>

Matsuura Y., Kusunoki M., Harada W. & Kakudo M. 1984. Structure and possible catalytic residues of Taka-amylase A. *J. Biochem.* **95**: 697–702.  
<https://doi.org/10.1093/oxfordjournals.jbchem.a134659>

Nelson K.E., Clayton R.A., Gill S.R., Gwinn M.L., Dodson R.J., Haft D.H., Hickey E.K., Peterson J.D., Nelson W.C., Ketchum K.A., McDonald L., Utterback T.R., Malek J.A., Linher K.D., Garrett M.M., Stewart A.M., Cotton M.D., Pratt M.S., Phillips C.A., Richardson D., Heidelberg J., Sutton G.G., Fleischmann R.D., Eisen J.A., White O., Salzberg S.L., Smith H.O., Venter J.C. & Fraser C.M. 1999. Evidence for lateral gene transfer between Archaea and Bacteria from genome sequence of *Thermotoga maritima*. *Nature* **399**: 323–329. <https://doi.org/10.1038/20601>

Ogasawara O., Kodama Y., Mashima J., Kosuge T. & Fujisawa T. 2020. DDBJ Database updates and computational infrastructure enhancement. *Nucleic Acids Res.* **48 (Database Issue 1)**: D45–D50. <https://doi.org/10.1093/nar/gkz982>

Oslancova A. & Janecek S. 2002. Oligo-1,6-glucosidase and neopullulanase enzyme subfamilies from the α-amylase family defined by the fifth conserved sequence region. *Cell. Mol. Life. Sci.* **59**: 1945–1959. <https://doi.org/10.1007/pl00012517>

Parkhill J., Wren B.W., Thomson N.R., Titball R.W., Holden M.T., Prentice M.B., Sebaihia M., James K.D., Churcher C., Mungall K.L., Baker S., Basham D., Bentley S.D., Brooks K., Cerdeno-Tarraga A.M., Chillingworth T., Cronin A., Davies R.M., Davis P., Dougan G., Feltwell T., Hamlin N., Holroyd S., Jagels K., Karlyshev A.V., Leather S., Moule S., Oyston P.C., Quail M., Rutherford K., Simmonds M., Skelton J., Stevens K., Whitehead S. & Barrell B.G. 2001. Genome sequence of *Yersinia pestis*, the causative agent of plague. *Nature* **413**: 523–527. <https://doi.org/10.1038/35097083>

Rost B., Yachdav G. & Liu J. 2004. The PredictProtein server. *Nucleic Acids Res.* **32 (Web Server issue)**: W321–W326. <https://doi.org/10.1093/nar/gkh377>

Saitou N. & Nei M. 1987. The neighbor-joining method: a new method for reconstructing phylogenetic trees. *Mol. Biol. Evol.* **4**: 406–425.  
<https://doi.org/10.1093/oxfordjournals.molbev.a040454>

Sanger F., Air G.M., Barrell B.G., Brown N.L., Coulson A.R., Fiddes C.A., Hutchison C.A., Slocombe P.M. & Smith M. 1977. Nucleotide sequence of bacteriophage φX174 DNA. *Nature* **265**: 687–695. <https://doi.org/10.1038/265687a0>

Sarian F.D., Janecek S., Pijning T., Ihsanawati, Nurachman Z., Radjasa O.K., Dijkhuizen L., Natalia D. & van der Maarel M.J. 2017. A new group of glycoside hydrolase family 13 α-amylases with an aberrant catalytic triad. *Sci. Rep.* **7**: 44230.  
<https://doi.org/10.1038/srep44230>

Sayers E.W., Beck J., Brister J.R., Bolton EE., Canese K., Comeau D.C., Funk K., Ketter A., Kim S., Kimchi A., Kitts P.A., Kuznetsov A., Lathrop S., Lu Z., McGarvey K., Madden T.L., Murphy T.D., O'Leary N., Phan L., Schneider V.A., Thibaud-Nissen F., Trawick B.W., Pruitt K.D. & Ostell J. 2020. Database resources of the National Center for Biotechnology Information. *Nucleic Acids Res.* **48 (Database Issue 1)**: D9–D16.  
<https://doi.org/10.1093/nar/gkz899>

Sayers E.W., Cavanaugh M., Clark K., Ostell J., Pruitt K.D. & Karsch-Mizrachi I. 2020 GenBank. *Nucleic Acids Res.* **48 (Database Issue 1)**: D84–D86.  
<https://doi.org/10.1093/nar/gkz956>

Schwede T., Kopp J., Guex N. & Peitsch M.C. 2003. SWISS-MODEL: an automated protein homology-modeling server. *Nucleic Acids Res.* **31**: 3381–3385.  
<https://doi.org/10.1093/nar/gkg520>

Shatsky M., Nussinov R. & Wolfson H.J. 2004. A method for simultaneous alignment of multiple protein structures. *Proteins* **56**: 143–156.  
<https://doi.org/10.1002/prot.10628>

Sievers F., Wilm A., Dineen D., Gibson T.J., Karplus K., Li W., Lopez R., McWilliam H., Remmert M., Söding J., Thompson J.D. & Higgins D.G. 2011. Fast, scalable generation of high-quality protein multiple sequence alignments using Clustal Omega. *Mol. Syst. Biol.* **7**: 539. <https://doi.org/10.1038/msb.2011.75>

Tomb J.F., White O., Kerlavage A.R., Clayton R.A., Sutton G.G., Fleischmann R.D., Ketchum K.A., Klenk H.P., Gill S., Dougherty B.A., Nelson K., Quackenbush J., Zhou L., Kirkness E.F., Peterson S., Loftus B., Richardson D., Dodson R., Khalak H.G., Glodek A., McKenney K., Fitzgerald L.M., Lee N., Adams M.D., Hickey E.K., Berg D.E., Gocayne J.D., Utterback T.R., Peterson J.D., Kelley J.M., Cotton M.D., Weidman J.M., Fujii C., Bowman C., Watthey L., Wallin E., Hayes W.S., Borodovsky M., Karp P.D., Smith H.O., Fraser C.M. & Venter J.C. 1997. The complete genome sequence of the gastric pathogen *Helicobacter pylori*. *Nature* **388**: 539–547. <https://doi.org/10.1038/41483>

UniProt Consortium. 2019. UniProt: a worldwide hub of protein knowledge. *Nucleic Acids Res.* **47 (Database Issue 1)**: D506–D515. <https://doi.org/10.1093/nar/gky1049>

Venter J.C., Adams M.D., Myers E.W., Li P.W., Mural R.J., Sutton G.G., Smith H.O., Yandell M., Evans C.A., Holt R.A., Gocayne J.D., Amanatides P., Ballew R.M., Huson D.H., Wortman J.R., Zhang Q., Kodira C.D., Zheng X.H., Chen L., Skupski M., Subramanian G., Thomas P.D., Zhang J., Gabor Miklos G.L., Nelson C., Broder S., Clark A.G., Nadeau J., McKusick V.A., Zinder N., Levine A.J., Roberts R.J., Simon M., Slayman C., Hunkapiller M., Bolanos R., Delcher A., Dew I., Fasulo D., Flanigan M., Florea L., Halpern A., Hannenhalli S., Kravitz S., Levy S., Mobarry C., Reinert K., Remington K., Abu-Threideh J., Beasley E., Biddick K., Bonazzi V., Brandon R., Cargill M., Chandramouliwaran I., Charlab R., Chaturvedi K., Deng Z., Di Francesco V., Dunn P., Eilbeck K., Evangelista C., Gabrielian A.E., Gan W., Ge W., Gong F., Gu Z., Guan P., Heiman T.J., Higgins M.E., Ji R.R., Ke Z., Ketchum K.A., Lai Z., Lei Y., Li Z., Li J., Liang Y., Lin X., Lu F., Merkulov G.V., Milshina N., Moore H.M., Naik A.K., Narayan V.A., Neelam B., Nusskern D., Rusch D.B., Salzberg S., Shao W., Shue B., Sun J., Wang Z., Wang A., Wang X., Wang J., Wei M., Wides R., Xiao C., Yan C., Yao A., Ye J., Zhan M., Zhang W., Zhang H., Zhao Q., Zheng L., Zhong F., Zhong W., Zhu S., Zhao S., Gilbert D., Baumhueter S., Spier G., Carter C., Cravchik A., Woodage T., Ali F., An H., Awe A., Baldwin D., Baden H., Barnstead M., Barrow I., Beeson K., Busam D., Carver A., Center A., Cheng M.L., Curry L., Danaher S., Davenport L., Desilets R., Dietz S., Dodson K., Douc L., Ferriera S., Garg N., Gluecksmann A., Hart B., Haynes J., Haynes C., Heiner C., Hladun S., Hostin D., Houck J., Howland T., Ibegwam C., Johnson J., Kalush F., Kline L., Koduru S., Love A., Mann F., May D., McCawley S., McIntosh T., McMullen I., Moy M., Moy L., Murphy B., Nelson K., Pfannkoch C., Pratts E., Puri V., Qureshi H., Reardon M., Rodriguez R., Rogers Y.H., Romblad D., Ruhfel B., Scott R., Sitter C., Smallwood M., Stewart E., Strong R., Suh E., Thomas R., Tint N.N., Tse S., Vech C., Wang G., Wetter J., Williams S., Williams M., Windsor S., Winn-Deen E., Wolfe K., Zaveri J., Zaveri K., Abril J.F., Guigó R., Campbell M.J., Sjolander K.V., Karlak B., Kejariwal A., Mi H., Lazareva B., Hatton T., Narechania A., Diemer K., Muruganujan A., Guo N., Sato S., Bafna V., Istrail S., Lippert R., Schwartz R., Walenz B., Yoosheph S., Allen D., Basu A., Baxendale J., Blick L., Caminha M., Carnes-Stine J., Caulk P., Chiang Y.H., Coyne M., Dahlke C., Mays A., Dombroski M., Donnelly M., Ely D., Esparham S., Fosler C., Gire H., Glanowski S., Glasser K., Glodek A., Gorokhov M., Graham K., Gropman B., Harris M., Heil J., Henderson S., Hoover J., Jennings D., Jordan C., Jordan J., Kasha J., Kagan L., Kraft C., Levitsky A., Lewis M., Liu X., Lopez J., Ma D., Majoros W., McDaniel J., Murphy S., Newman M., Nguyen T., Nguyen N., Nodell M., Pan S., Peck J., Peterson M., Rowe W., Sanders R., Scott J., Simpson M., Smith T., Sprague A., Stockwell T., Turner R., Venter E., Wang M., Wen M., Wu D., Wu M., Xia A., Zandieh A. & Zhu X. 2001. The sequence of the human genome. *Science* **291**: 1304–1351. <https://doi.org/10.1126/science.1058040>

Venter J.C., Smith H.O. & Hood L. 1996. A new strategy for genome sequencing. *Nature* **381**: 364–366. <https://doi.org/10.1038/381364a0>

White O., Eisen J.A., Heidelberg J.F., Hickey E.K., Peterson J.D., Dodson R.J., Haft D.H., Gwinn M.L., Nelson W.C., Richardson D.L., Moffat K.S., Qin H., Jiang L., Pamphile W., Crosby M., Shen M., Vamathevan J.J., Lam P., McDonald L., Utterback T., Zalewski C., Makarova K.S., Aravind L., Daly M.J., Minton K.W., Fleischmann R.D., Ketchum K.A., Nelson K.E., Salzberg S., Smith H.O., Venter J.C. & Fraser C.M. 1999. Genome sequence of the radioresistant bacterium *Deinococcus radiodurans* R1. *Science* **286**: 1571–1577. <https://doi.org/10.1126/science.286.5444.1571>

Woese C.R. & Fox G.E. 1977. Phylogenetic structure of the prokaryotic domain: the primary kingdoms. *Proc. Natl. Acad. Sci. USA* **74**: 5088–5090.  
<https://doi.org/10.1073/pnas.74.11.5088>

wwPDB consortium. 2019. Protein Data Bank: the single global archive for 3D macromolecular structure data. *Nucleic Acids Res.* **47 (Database Issue 1)**: D520–D528. <https://doi.org/10.1093/nar/gky949>

Yachdav G., Kloppmann E., Kajan L., Hecht M., Goldberg T., Hamp T., Höninghschmid P., Schafferhans A., Roos M., Bernhofer M., Richter L., Ashkenazy H., Punta M., Schlessinger A., Bromberg Y., Schneider R., Vriend G., Sander C., Ben-Tal N. & Rost B. 2014. PredictProtein – an open resource for online prediction of protein structural and functional features. *Nucleic Acids Res.* **42 (Web Server issue)**: W337–W343.  
<https://doi.org/10.1093/nar/gku366>

Zamocky M., Janecek S. & Koller F. 2000. Common phylogeny of catalase-peroxidases and ascorbate peroxidases. *Gene* **256**: 169–182. [https://doi.org/10.1016/s0378-1119\(00\)00358-9](https://doi.org/10.1016/s0378-1119(00)00358-9)

Zhang Z., Schäffer A.A., Miller W., Madden T.L., Lipman D.J., Koonin E.V. & Altschul S.F. 1998. Protein sequence similarity searches using patterns as seeds. *Nucleic Acids Res.* **26**: 3986–3990. <https://doi.org/10.1093/nar/26.17.3986>

# **BIOINFORMATIKA PROTEÍNOV**

**Autor:** Doc. Ing. Štefan Janeček, DrSc.

**Vydala:** Univerzita sv. Cyrila a Metoda v Trnave, 2020

**Vydanie:** prvé.

**Web:** [http://fpv.ucm.sk/images/ucebne\\_texty/Bioinformatika\\_proteinov.pdf](http://fpv.ucm.sk/images/ucebne_texty/Bioinformatika_proteinov.pdf)

**Počet strán:** 106

**ISBN 978-80-572-0085-7**