

My first scientific paper  
Week 5  
**Highlight the principles**



Vadim Strijov

Moscow Institute of Physics and Technology


2021

# Задачи структурной биологии для белков длины $m$


$$\mathcal{A} = \{\text{Ala, Arg, Asn, Asp, Cys, Glu, Gln, Gly, His, \dots, Trp, Tyr, Val}\}$$




# When one needs a multimodel?



Sample generation assumption




Real data



Model posterior distribution

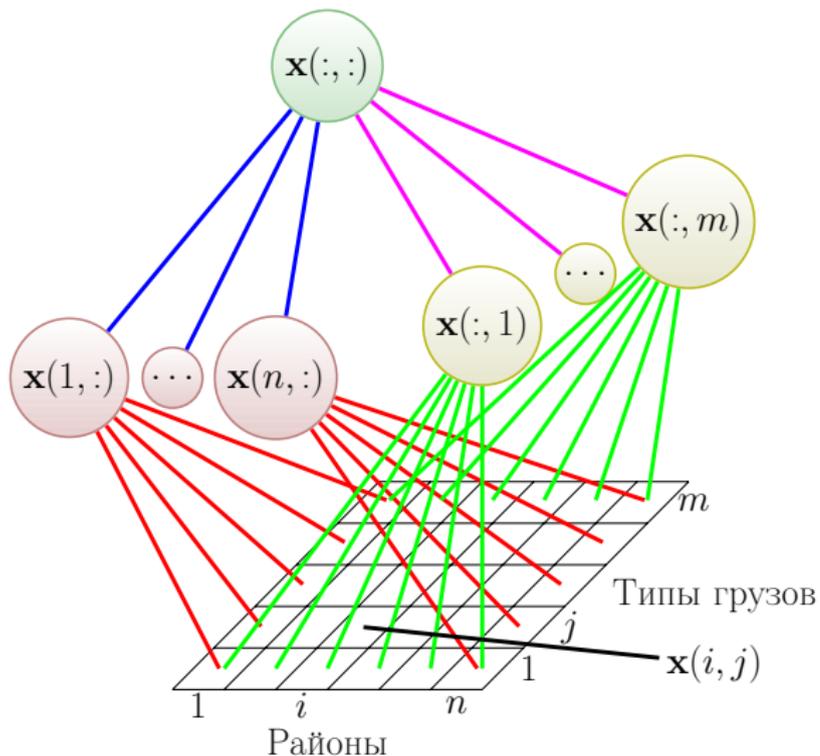
$$p(\mathbf{w}|\mathbf{X}, \mathbf{y})$$



Real posterior distribution

$$p(\mathbf{w}|\mathbf{X}, \mathbf{y})$$

# Условие согласованности прогнозов



$$x_t(:, :) = \sum_{i=1}^n x_t(i, :);$$

$$x_t(:, :) = \sum_{j=1}^m x_t(:, j);$$


$$x_t(i, :) = \sum_{j=1}^m x_t(i, j),$$

$$i = 1, \dots, n;$$


$$x_t(:, j) = \sum_{i=1}^n x_t(i, j),$$

$$j = 1, \dots, m;$$


$$t = 1, \dots, T.$$



# Анализ спутниковых снимков




*Скорость движения вдоль направления наблюдения*



*Погрешность в высоте*

Рудаков К.В., Адуенко А.А., Рейер И.А., Василейский А.С., Карелов А.И., Стрижов В.В.  
Алгоритмы выделения и смещения устойчивых отражателей на спутниковых снимках // Компьютерная оптика, 2015.

# Структура решения



# Задача регрессии в пространстве мультииндексных признаков


Решается задача восстановления регрессии

$$\hat{\mathbf{y}} = \sum_{i_1, \dots, i_D} [\underline{\mathbf{X}} * \underline{\mathbf{W}}]_{i_1 \dots i_D}, \quad \underline{\mathbf{W}} = \arg \min_{\mathbf{W}} \sum_{m=1}^M \|\underline{\mathbf{X}}_m * \underline{\mathbf{W}} - \mathbf{y}_m\|_F^2.$$

где  $\mathbf{y} \in \mathbb{R}^n$ ,  $\underline{\mathbf{X}}, \underline{\mathbf{W}} \in \mathbb{R}^{n_1 \times \dots \times n_D}$  — мультииндексные матрицы,  $*$  обозначает операцию поэлементного умножения.

В векторном виде задача имеет вид  $\mathbf{y} = \mathbf{x}^T \mathbf{w}$ , где


$$\mathbf{x} = \text{vec}(\underline{\mathbf{X}}) = x_{i_1(n_1-1) + \dots + i_{D-1}(n_{D-1}-1) + i_D} = [\underline{\mathbf{X}}]_{i_1 \dots i_D}.$$







# Описание молекулярной химической связи

В данной работе исследуются взаимные пространственные ориентации различных пар молекул, образующих между собой химическую связь. Эта связь характеризуется тремя параметрами:

- $r$  — расстояние между молекулами,  $r \in [3\text{\AA}, 20\text{\AA}]$ ;
- $(\theta, \varphi)$  — пара сферических углов, определяющих положение лиганда в системе координат аминокислоты,  $\theta \in [0, \pi]$ ,  $\varphi \in [0, 2\pi]$ .



# Представление выборки для пары ALA-C<sub>ar</sub>



## Сегментирование квазипериодического временного ряда

Квазипериодический временной ряд  $\mathbf{s} = \{s(t_1), \dots, s(t_i), \dots, s(t_m)\}$  длины  $m$  определяется набором  $\langle \mathbf{s}^*, a(i, s), f(i) \rangle$ , так что

$$s(t_i) = a(i, s_{[f(i)]}),$$

где  $\mathbf{s}^* = [s_1, \dots, s_T]^T$  — базовый сегмент,

$a(i, s), i \in \{1, \dots, m\}$  — трансформация формы

базового сегмента,  $f(i) \mapsto \{1, \dots, T\}$  —

масштабирование по времени.

### Теорема (Мотренко)

Для временного ряда  $\mathbf{s}$

вида  $s(t_i) = A_i \cos(2\pi w i + \phi)$  с  $w \in (0, 1/2)$ ,

$\phi \in [0, 2\pi)$ ,  $m \cdot w \in \mathbb{N}$  и  $A_i : \exists C \in \mathbb{R} |A_i| < C \forall i$



главные компоненты  $\mathbf{y}_1$  и  $\mathbf{y}_2$  могут быть представлены в виде

$$y_1(l) = B_1(l) \cos(2\pi w l + \phi_1),$$



$$y_2(l) = B_2(l) \cos(2\pi w l + \phi_2),$$

$$\phi_1, \phi_2 \in [0, 2\pi), l = 1, \dots, m - N + 1$$


где разница между  $|\phi_1 - \phi_2| \rightarrow \pi/2$ .



# Восстановление зависимости в исходном и целевом пространствах



## Прогностическая модель декодирования





## Согласование зависимостей в скрытом пространстве

$$\begin{array}{ccc}
 \mathbf{x} \in \mathbb{R}^n & \xrightarrow{\mathbf{f}} & \mathbf{y} \in \mathbb{R}^r \\
 \swarrow \mathbf{W} & & \searrow \mathbf{Q} \\
 & \mathbf{t}, \mathbf{u} \in \mathbb{R}^\ell & \\
 \nwarrow \mathbf{P} & & \nearrow \mathbf{C} \\
 \mathbf{x} = \mathbf{P}\mathbf{t} + \mathbf{e}_x & & \mathbf{y} = \mathbf{Q}\mathbf{u} + \mathbf{e}_y \\
 \text{cov}(\mathbf{t}, \mathbf{u}) \rightarrow \max_{\mathbf{P}, \mathbf{Q}} & & 
 \end{array}$$

# Пример согласованной проекции в скрытое пространство

Исходные переменные  $\mathbf{x}_i \sim \mathcal{N}(0, \Sigma)$ .

Целевые переменные  $\mathbf{y}_i$  линейно зависят от  $pc_2$  и не зависят от  $pc_1$ .




Согласование проекций матриц  $\mathbf{X}$  и  $\mathbf{Y}$  находит оптимальное скрытое представление, отклоняя вектора  $\mathbf{w}_k$  и  $\mathbf{c}_k$  от направления главных компонент.


# Априорное распределение на структуре модели

Каждая точка на симплексе задает модель.


Распределение Гумбель-софтмакс:  $\Gamma \sim GS(s, \lambda_{temp})$



$$\lambda_{temp} \rightarrow 0$$




$$\lambda_{temp} = 0.995$$



$$\lambda_{temp} = 5.0$$


Распределение Дирихле:  $\Gamma \sim Dir(s, \lambda_{temp})$



$$\lambda_{temp} \rightarrow 0$$



$$\lambda_{temp} = 0.995$$




$$\lambda_{temp} = 5.0$$

# Байесовский выбор модели

## Базовая модель:

- параметры модели  $\mathbf{w} \sim \mathcal{N}(0, \alpha^{-1})$ ,
- гиперпараметры модели  $\mathbf{h} = [\alpha]$ .



## Предлагаемая модель:

- параметры модели  $\mathbf{w}_r^{j,k} \sim \mathcal{N}(0, \gamma_r^{j,k} (\mathbf{A}_r^{j,k})^{-1})$ ,  $\mathbf{A}_r^{j,k}$  — диагональная матрица параметров, соответствующих базовых функций  $\mathbf{g}_r^{j,k}$ ,  $(\mathbf{A}_r^{j,k})^{-1} \sim \text{inv-gamma}(\lambda_1, \lambda_2)$ ,
- структурные параметры модели  $\Gamma = \{\gamma^{j,k}, (j, k) \in E\}$ ,  $\gamma^{j,k} \sim \text{GS}(s^{j,k}, \lambda_{\text{temp}})$ ,
- гиперпараметры модели  $\mathbf{h} = [\text{diag}(\mathbf{A}), s]$ ,
- метапараметры  $\lambda_1, \lambda_2, \lambda_{\text{temp}}$ .

# Верхняя оценка правдоподобия модели

Оптимальные факторы  $q^*(\theta)$ ,  $q^*(\mathbf{m}, \mathbf{V}, \alpha)$  имеют вид

$$\ln q^* = E[\ln p(\mathbf{Z}, \theta, \mathbf{m}, \mathbf{V}, \alpha)] + \text{const}$$

и не вычисляются аналитически, так как правдоподобие  $L$  в модели  $p(\mathbf{Z}, \theta, \mathbf{m}, \mathbf{V}, \alpha)$  содержит сумму экспонент  $g(\mathbf{s}_n)$  в знаменателе,


$$L(\mathbf{Z}|\theta, \alpha) = \prod_{n=1}^N \prod_{k=1}^{K_h} \left[ \frac{\exp(s_{n,k})}{g(\mathbf{s}_n)} \right]^{z_{nk}}, \quad g(\mathbf{s}_n) = \sum_{k=1}^{K_h} \exp(s_{n,k}).$$

$\ln \frac{1}{g(\mathbf{x})}$  – вогнутая функция. Касательная плоскость к ней через точку  $\xi$ :

$$\zeta(\mathbf{x}, \xi) = -\ln(g(\xi)) - \nabla \ln(g(\xi))^T (\mathbf{x} - \xi).$$

Верхняя оценка правдоподобия  $L$

$$\frac{1}{g(\xi)} \exp \left( s_{n,k} + \sum_{k'=1}^{K_h} \frac{\exp(\xi_{k'})}{g(\xi)} (\xi_{k'} - s_{n,k'}) \right).$$



## Анализ качества предлагаемого метода выбора признаков

Решена задача прогнозирования многомерных временных рядов  $\mathbf{y}(t) \in \mathbb{R}^3$  координат конечности по интервалам  $\mathbf{s}(t - \Delta t)$  многомерных временных рядов  $\mathbf{s}(t) \in \mathbb{R}^{N_{\text{ch}}}$  многоканальных электрокортикограмм.

Признаки:

$$\underline{\mathbf{X}}_m \in \mathbb{R}^{F \times N_{\text{ch}}}, \quad \underline{\mathbf{X}}_{mjn} = \begin{cases} s_n(t_m + \tau), & j = 1, \\ W_{mjn}, & j = 2, \dots, F + 1, \end{cases}$$

Прогноз в точке  $t_m$ :

$$\hat{\mathbf{y}}_m = \text{vec}(\underline{\mathbf{X}}_m)^T \hat{\mathbf{w}}.$$


Качество прогнозирования:

коэффициент корреляции между  $\hat{\mathbf{Y}}$  и  $\mathbf{Y}$ ,


$$\text{corr}(\hat{\mathbf{Y}}, \mathbf{Y}) = \frac{\text{cov}(\hat{\mathbf{y}}, \mathbf{y})}{\sqrt{\text{cov}(\hat{\mathbf{y}}, \hat{\mathbf{y}})\text{cov}(\mathbf{y}, \mathbf{y})}}.$$

масштабированная ошибка MSE,


$$\text{sMSE}(\hat{\mathbf{Y}}, \mathbf{Y}) = \frac{\sum_{m=1}^M \|\hat{\mathbf{y}}_m - \mathbf{y}_m\|_2}{\sum_{m=1}^M \|\bar{\mathbf{y}} - \mathbf{y}_m\|_2}.$$




# Снижение размерности с сохранением локальной структуры близости




Построение признакового пространства для ряда  $s$



Модифицированный t-SNE,  $\mu = 10$





Исходный t-SNE



Модифицированный t-SNE,  $\mu = 100$


# Результаты для опциона CLZ

$$\sigma = \frac{(w_1 K + w_2)(w_1 K^2 + w_2 K + w_3)^2}{\sqrt{t}}$$



# Декодируемые сигналы электрокортикограммы

- Сигналы  $\mathbf{s}(t) \in \mathbb{R}^{N_{ch}}$ .  $N_{ch}$  – число электродов
- Координаты электродов  $\mathbf{Z} = \{(\mathbf{z}_j \in \mathbb{R}^2, j \in \{1 \dots, N_{ch}\})\}$
- Положение кисти в пространстве  $\mathbf{y}(t) \in \mathbb{R}^3$



Координата руки




Пространственное  
расположение  
электродов

Chao ZC, Nagasaka Y, Fujii N (2010). "Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys." *Frontiers in Neuroengineering* 3:3.

# Банк тем: сохранение интерпретируемых тем

Банк тем — модель  
полного набора тем:  
таких тем, которые

- 1) интерпретируемы,
- 2) существенно  
различны,
- 3) обеспечивают  
высокое  
правдоподобие  
модели  
 $p(\Phi, \Theta | D)$ .




# Построение банка тем

Аналогично построению двухуровневой иерархической тематической модели:

$$\underbrace{p(w | t)}_{\varphi_{wt}^{parent}} = \sum_{s \in S} \underbrace{p(w | s)}_{\varphi_{ws}^{child}} \underbrace{p(s | t)}_{\psi_{st}} \quad \text{Hierarchy}$$



$$\underbrace{p(w | t)}_{\varphi_{wt}^{bank}} = \sum_{s \in S} \underbrace{p(w | s)}_{\varphi_{ws}^{new}} \underbrace{p(s | t)}_{\psi_{st}} \quad \text{TopicBank}$$



№	Hierarchy	TopicBank
1	ok	no
2	ok	ok
3	no	ok
4	ok	maybe
5	ok	maybe


# Фазовая траектория

На рисунке представлен временной ряд и проекция его фазовой траектории в трехмерное пространство.  $\mathbf{x}_t = \mathbf{x}(t)$  – точка на фазовой траектории в момент времени  $t$ .




Сегмент — последовательность точек временного ряда, которая относится к одному характерному физическому действию человека: шаг, прыжок.

Цепь — последовательность сегментов, которые образуют квазипериодическую последовательность точек.




(a)



(b)



а) временной ряда разбитый на сегменты; б) проекции на плоскость фазовых траекторий временного ряда, которые относятся к Type 1 и Type 2.

# Ближайшие соседи на фазовых траекториях



# Empirical distribution of model parameters

The value of error function  $S(\mathbf{w}|\mathcal{D}, f)$  depends on parameters.



x-axis and y-axis: parameters  $\mathbf{w}$ , z-axis:  $\exp(-S(\mathbf{w}))$

# Probabilistic model selection

Bayesian inference delivers the error function  $S(\mathbf{w})$

$$p(\mathbf{w}|\mathcal{D}, \mathbf{A}, \mathbf{B}, \mathbf{f}) = \frac{p(\mathcal{D}|\mathbf{w}, \mathbf{B}, \mathbf{f})p(\mathbf{w}|\mathbf{A}, \mathbf{f})}{p(\mathcal{D}|\mathbf{A}, \mathbf{B}, \mathbf{f})}.$$

Posterior      Likelihood      Prior

Evidence  
(to select a model)


Write the error function given hyperparameters  $\mathbf{A}, \mathbf{B}$

$$S(\mathbf{w}) = \underbrace{\frac{1}{2}(\mathbf{y} - \mathbf{f})^T \mathbf{B}(\mathbf{y} - \mathbf{f})}_{\text{approximation error}} + \underbrace{\frac{1}{2}(\mathbf{w} - \hat{\mathbf{w}})^T \mathbf{A}(\mathbf{w} - \hat{\mathbf{w}})}_{\text{regularisation error}},$$

$$S = E_D + E_w = \lambda^T \mathbf{s}, \quad \text{metaparameters } \lambda = \frac{1}{2}.$$


# Evidence of the model

depends on both, error  $E_D$  (likelihood) and regularisation  $E_w$  (prior).




Parameters  $w$ , variance  $\alpha^{-2}$ , and  $p(w|\mathcal{D}, \alpha)$  is the evidence.

# – Error and its variance for a reinforced sample set



# Variance of error increasing over model complexity







Complexity, number of model parameters

## Resulting models

### Resulting model



$$\sigma_{imp} = \frac{(k_2 M + k_3)^4 + k_4 M + c}{\sqrt{k_1 t}}$$











Пн Bc




Пн Bc






Пн Bc





Пн Bc



















a)



b)






# Тематическое моделирование и матричное разложение




$w_1, \dots, w_{n_d}$ :



Разработан спектрально-аналитический подход к выявлению размытых протяженных повторов в геномных последовательностях. Метод основан на разномасштабном оценивании сходства нуклеотидных последовательностей в пространстве коэффициентов разложения фрагментов кривых GC- и GA-содержания по классическим ортогональным базисам. Найдены условия оптимальной аппроксимации, обеспечивающие автоматическое распознавание повторов различных видов (прямых и инвертированных, а также тандемных) на спектральной матрице сходства. Метод одинаково хорошо работает на разных масштабах данных. Он позволяет выявлять следы сегментных дупликаций и мегасателлитные участки в геноме, районы синтении при сравнении пары геномов. Его можно использовать для детального изучения фрагментов хромосом (поиска размытых участков с умеренной длиной повторяющегося паттерна).




$$\zeta_1 = [1; 1],$$

$$\zeta_2 = [1; 0]$$






Пустые круги — истинные полутона, точки — предсказанные, ошибки подсвечены, горизонтальная ось — время.



(a) Высота



(б) Фазовая составляющая без учета шума

