

Selekcja zmiennych w klasyfikacji  
wielo-etykietowej w oparciu o łańcuchy  
klasyfikatorów i sieć elastyczną

Paweł Teisseyre

Instytut Podstaw Informatyki PAN

# Plan prezentacji

- ▶ Klasyfikacja z wieloma etykietami.
- ▶ Metoda CCnet: łańcuchy klasyfikatorów + sieć elastyczna.
- ▶ Eksperymenty.

# Klasyfikacja z wieloma etykietami

## Klasyfikacja z jedną etykietą

- ▶ Jedna zmienna odpowiedzi.
- ▶ Zbiór uczący:  $(\mathbf{x}_i, y_i)$ ,  $\mathbf{x}_i \in R^p$ ,  $y_i \in \{0, 1\}$ .

## Klasyfikacja z wieloma etykietami

- ▶ Wiele zmiennych odpowiedzi.
- ▶ Zbiór uczący:  $(\mathbf{x}_i, \mathbf{y}_i)$ ,  $\mathbf{x}_i \in R^p$ ,  $\mathbf{y}_i \in \{0, 1\}^K$ .

## Przykład: wielozachorowalność

BMI	Weight	Glucose	...	Diabetes	Hypotension	Liver disease	...
31	84	10	...	1	0	1	...
26	63	6	...	1	0	0	...
27	60	7	...	0	0	0	...

**Zmienne x:** charakterystyki pacjentów.

**Etykiety y:** wystąpienia chorób.

- ▶ Zadanie 1: przewidywanie które choroby wystąpią na podstawie pewnych charakterystyk pacjentów (**PREDYCKJA**).
- ▶ Zadanie 2: wyznaczenie które zmienne wpływają na występowanie poszczególnych chorób (**SELEKCJA ZMIENNYCH**).

# Klasyfikacja z wieloma etykietami

## Naturalne podejście:

1. Oszacowanie prawdopodobieństwa a posteriori:

$$p(\mathbf{y}|\mathbf{x})$$

2. Predykcja dla nowej obserwacji  $\mathbf{x}_0$ :

$$\hat{\mathbf{y}}(\mathbf{x}_0) = \arg \max_{\mathbf{y} \in \{0,1\}^K} \hat{p}(\mathbf{y}|\mathbf{x}_0),$$

gdzie  $\hat{p}(\mathbf{y}|\mathbf{x}_0)$  to oszacowane prawdopodobieństwo a posteriori w  $\mathbf{x}_0$ .

# Metoda CCnet

## Estymacja prawdopodobieństwa a posteriori:

- ▶ Rozważamy rodzinę rozkładów:  $\{p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta\}$ .
- ▶ Estymujemy parametry używając metody NW:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) \right\}.$$

- ▶ Wersja z regularyzacją:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$

Zaleta regularyzacji  $\ell_1$ : część współrzędnych  $\hat{\boldsymbol{\theta}}$  będzie równa 0 (selekcja zmiennych).

# Metoda CCnet

## Estymacja prawdopodobieństwa a posteriori:

- ▶ Rozważamy rodzinę rozkładów:  $\{p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta\}$ .
- ▶ Estymujemy parametry używając metody NW:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) \right\}.$$

- ▶ Wersja z regularyzacją:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$

Zaleta regularyzacji  $\ell_1$ : część współrzędnych  $\hat{\boldsymbol{\theta}}$  będzie równa 0 (selekcja zmiennych).

# Metoda CCnet

## Estymacja prawdopodobieństwa a posteriori:

- ▶ Rozważamy rodzinę rozkładów:  $\{p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta\}$ .
- ▶ Estymujemy parametry używając metody NW:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)}|\mathbf{x}^{(i)}, \boldsymbol{\theta}) \right\}.$$

- ▶ Wersja z regularyzacją:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)}|\mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$

Zaleta regularyzacji  $\ell_1$ : część współrzędnych  $\hat{\boldsymbol{\theta}}$  będzie równa 0 (selekcja zmiennych).



# Metoda CCnet

## Estymacja prawdopodobieństwa a posteriori:

- ▶ Rozważamy rodzinę rozkładów:  $\{p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta\}$ .
- ▶ Estymujemy parametry używając metody NW:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)}|\mathbf{x}^{(i)}, \boldsymbol{\theta}) \right\}.$$

- ▶ Wersja z regularyzacją:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)}|\mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$

Zaleta regularyzacji  $\ell_1$ : część współrzędnych  $\hat{\boldsymbol{\theta}}$  będzie równa 0 (selekcja zmiennych).

## Estymacja prawdopodobieństwa a posteriori:

- ▶ Zamiast modelować  $p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta})$  bezpośrednio, używamy wzoru łańcuchowego:

$$p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) = p(y_1|\mathbf{x}, \boldsymbol{\theta}_1) \prod_{k=2}^K p(y_k|\mathbf{y}_{-k}, \mathbf{x}, \boldsymbol{\theta}_k),$$

gdzie:  $\mathbf{y}_{-k} = (y_1, \dots, y_{k-1})^T$ ,  $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_K)^T$ .

# Metoda CCnet

- ▶ Problem:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$



- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(y_k^{(i)} | \mathbf{y}_{-k}^{(i)}, \mathbf{x}^{(i)}, \boldsymbol{\theta}_k) + \lambda_1 \|\boldsymbol{\theta}_k\|_1 + \lambda_2 \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .

# Metoda CCnet

- ▶ Problem:

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}, \boldsymbol{\theta}) + \lambda_1 \|\boldsymbol{\theta}\|_1 + \lambda_2 \|\boldsymbol{\theta}\|_2^2 \right\}.$$



- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(y_k^{(i)} | \mathbf{y}_{-k}^{(i)}, \mathbf{x}^{(i)}, \boldsymbol{\theta}_k) + \lambda_1 \|\boldsymbol{\theta}_k\|_1 + \lambda_2 \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .

## Metoda CCnet

- ▶ Zakładamy że prawdopodobieństwa warunkowe są w postaci:

$$p(y_k | \mathbf{z}_k, \boldsymbol{\theta}_k) = \frac{\exp(\boldsymbol{\theta}_k^T \mathbf{z}_k y_k)}{1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k)},$$

gdzie:  $\mathbf{z}_k = (\mathbf{y}_{-k}, \mathbf{x})^T$ .

- ▶ Rozważamy parametry regularyzacji  $\lambda_{1,k}$  and  $\lambda_{2,k}$  niezależnie, dla każdego  $k$ .



- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n [\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)} y_k^{(i)} - \log(1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)}))] + \lambda_{1,k} \|\boldsymbol{\theta}_k\|_1 + \lambda_{2,k} \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .

# Metoda CCnet

- ▶ Zakładamy że prawdopodobieństwa warunkowe są w postaci:

$$p(y_k | \mathbf{z}_k, \boldsymbol{\theta}_k) = \frac{\exp(\boldsymbol{\theta}_k^T \mathbf{z}_k y_k)}{1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k)},$$

gdzie:  $\mathbf{z}_k = (\mathbf{y}_{-k}, \mathbf{x})^T$ .

- ▶ Rozważamy parametry regularyzacji  $\lambda_{1,k}$  and  $\lambda_{2,k}$  niezależnie, dla każdego  $k$ .



- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n [\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)} y_k^{(i)} - \log(1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)}))] + \lambda_{1,k} \|\boldsymbol{\theta}_k\|_1 + \lambda_{2,k} \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .

# Metoda CCnet

- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n [\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)} y_k^{(i)} - \log(1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)}))] + \lambda_{1,k} \|\boldsymbol{\theta}_k\|_1 + \lambda_{2,k} \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .



- ▶  $K$  problemów optymalizacji wypukłej: do rozwiązania można użyć algorytmu CCD (funkcja `glmnet` w R).

# Metoda CCnet

- ▶ Rozwiązanie w postaci:  $\hat{\boldsymbol{\theta}} = (\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_K)^T$ , gdzie:

$$\hat{\boldsymbol{\theta}}_k = \arg \min_{\boldsymbol{\theta}_k} \left\{ -\frac{1}{n} \sum_{i=1}^n [\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)} y_k^{(i)} - \log(1 + \exp(\boldsymbol{\theta}_k^T \mathbf{z}_k^{(i)}))] + \lambda_{1,k} \|\boldsymbol{\theta}_k\|_1 + \lambda_{2,k} \|\boldsymbol{\theta}_k\|_2^2 \right\},$$

dla  $k = 1, \dots, K$ .



- ▶  $K$  problemów optymalizacji wypukłej: do rozwiązania można użyć algorytmu CCD (funkcja `glmnet` w R).



## Wybór parametru regularyzacji

- ▶ Przyjmujemy  $\lambda_{1,k} = \alpha\lambda_k$ ,  $\lambda_{2,k} = (1 - \alpha)\lambda_k$ , gdzie:  $\alpha \in [0, 1]$ .
- ▶ Dla ustalonego  $\alpha$  znajdujemy optymalną wartość  $\lambda_k$  używając kryterium **GIC (Generalized Information Criterion)**:

$$\hat{\lambda}_k = \arg \min_{\lambda_k} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(y_k^{(i)} | \mathbf{z}_k^{(i)}, \hat{\boldsymbol{\theta}}_k) + a(n) \cdot df \right\},$$

gdzie:

- ▶  $df := |\{r : \hat{\boldsymbol{\theta}}_{k,r} \neq 0\}|$ ,
- ▶  $a(n) = \log(n)$  (BIC) lub  $a(n) = 2$  (AIC).

# Wyniki teoretyczne

- ▶ **Stabilność CCnet ze względu na wybraną funkcję straty:** niewielka zmiana zbioru treningowego nie wpływa znacząco na wartość funkcji straty dla CCnet.
- ▶ **Oszacowanie błędu generalizacji dla CCnet, dla wybranej funkcji straty:** używamy pomysłu opisanego w pracy Bousquet & Elisseeff (JMLR 2002), który pozwala udowodnić oszacowanie błędu generalizacji używając stabilności.

# Eksperymenty

## Porównanie metod:

1. *BRlogit*<sup>1</sup>,
2. *BRtree*,
3. *BRnet*, dla  $\alpha = 0, 0.5, 1^2$ ,
4. *CClogit*<sup>3</sup>,
5. *CCtree*,
6. *CCnet*, dla  $\alpha = 0, 0.5, 1$ .

---

<sup>1</sup>Dembczynski et. al. 2012

<sup>2</sup>Liu 2015

<sup>3</sup>Kumar et. al. 2013; Montanes 2014; Dembczynski et. al. 2012

# Eksperymenty

## Miary oceny:

- ▶ Dokładność zbioru:

$$\text{Subset accuracy}(\mathbf{y}, \hat{\mathbf{y}}) = I[\mathbf{y} = \hat{\mathbf{y}}].$$

- ▶ Miara Hamminga:

$$\text{Hamming measure}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{K} \sum_{k=1}^K I[y_k = \hat{y}_k].$$

- ▶ Liczba wybranych zmiennych.
- ▶ Czas budowy modelu.

# Eksperymenty

Dataset	CClogit	CCtree	CCnet ( $\alpha = 1$ )	CCnet ( $\alpha = 0$ )	CCnet ( $\alpha = 0.5$ )	BRlogit	BRtree	BRnet ( $\alpha = 1$ )	BRnet ( $\alpha = 0$ )	BRnet ( $\alpha = 0.5$ )
music	0.215	0.221	0.275	0.267	<b>0.282</b>	0.186	0.191	0.257	0.253	0.220
yeast	0.214	0.168	0.184	<b>0.226</b>	0.192	0.156	0.048	0.123	0.163	0.115
scene	0.473	0.467	0.629	<b>0.639</b>	0.592	0.385	0.337	0.416	0.543	0.356
birds	0.349	0.375	0.532	0.535	<b>0.538</b>	0.332	0.375	0.535	0.535	0.538
flags	<b>0.227</b>	0.139	0.216	0.196	0.196	0.124	0.072	0.165	0.139	0.144
medical	0.181	0.690	<b>0.760</b>	0.218	0.697	0.180	0.634	0.752	0.218	0.667
cal500	0.008	0.006	<b>0.020</b>	0.014	0.020	0.012	0.004	0.008	0.010	0.010
genbase	<b>0.989</b>	0.985	0.986	0.029	0.986	0.989	0.985	0.989	0.029	0.986
mediamill	0.223	0.096	0.197	<b>0.200</b>	0.197	0.192	0.057	0.155	0.160	0.156
enron	0.037	0.170	0.139	<b>0.210</b>	0.136	0.038	0.130	0.095	0.202	0.090
bookmarks	0.108	0.287	<b>0.754</b>	0.741	0.754	0.067	0.292	0.754	0.739	0.754
bibtex	0.361	0.404	0.780	<b>0.788</b>	0.777	0.359	0.414	0.780	0.787	0.777
avg rank	5.269	4.077	<b>7.769</b>	<b>7.769</b>	7.577	3.500	2.538	5.808	5.769	4.923

Tabela : Dokładność zbioru. Parametr  $\lambda$  wybrany za pomocą BIC.  
Pogrubione liczby odpowiadają najlepszej metodzie.

# Eksperymenty

Dataset	CClogit	CCtree	CCnet ( $\alpha = 1$ )	CCnet ( $\alpha = 0$ )	CCnet ( $\alpha = 0.5$ )	BRlogit	BRtree	BRnet ( $\alpha = 1$ )	BRnet ( $\alpha = 0$ )	BRnet ( $\alpha = 0.5$ )
music	0.749	0.720	0.775	0.782	0.778	0.765	0.734	0.794	<b>0.796</b>	0.783
yeast	0.722	0.659	0.724	0.731	0.730	0.741	0.631	0.744	<b>0.744</b>	0.742
scene	0.843	0.838	0.884	0.900	0.873	0.846	0.831	0.887	<b>0.901</b>	0.878
birds	0.809	0.864	0.923	0.915	0.922	0.804	0.863	<b>0.924</b>	0.914	0.922
flags	0.706	0.658	<b>0.733</b>	0.719	0.728	0.716	0.669	0.731	0.725	0.721
medical	0.774	0.956	<b>0.968</b>	0.906	0.962	0.773	0.955	0.967	0.906	0.959
cal500	0.588	0.545	0.616	0.608	<b>0.616</b>	0.596	0.541	0.615	0.600	0.616
genbase	0.999	0.998	0.999	0.901	0.999	0.999	0.998	<b>0.999</b>	0.901	0.999
mediamill	0.825	0.703	0.816	0.820	0.816	<b>0.833</b>	0.688	0.822	0.825	0.823
enron	0.589	0.780	0.806	<b>0.834</b>	0.809	0.605	0.772	0.816	0.834	0.815
bookmarks	0.719	0.770	<b>0.969</b>	0.967	0.969	0.684	0.822	0.969	0.967	0.969
bibtex	0.895	0.902	0.975	0.976	0.975	0.898	0.913	0.975	<b>0.976</b>	0.975
avg rank	3.654	2.654	6.654	6.308	6.308	4.423	2.500	<b>8.192</b>	7.231	7.077

Tabela : Miara Hamminga. Parametr  $\lambda$  wybrany za pomocą BIC.  
Pogrubione liczby odpowiadają najlepszej metodzie.

# Eksperymenty

Dataset	CClogit	CCtree	CCnet ( $\alpha = 1$ )	CCnet ( $\alpha = 0$ )	CCnet ( $\alpha = 0.5$ )	BRlogit	BRtree	BRnet ( $\alpha = 1$ )	BRnet ( $\alpha = 0$ )	BRnet ( $\alpha = 0.5$ )
music	71	69	36	71	45	71	71	<b>34</b>	71	39
yeast	103	95	70	103	85	103	103	<b>54</b>	103	59
scene	294	177	161	294	212	294	190	<b>160</b>	294	190
birds	260	34	44	260	<b>30</b>	260	33	45	260	30
flags	19	19	16	19	16	19	19	<b>6</b>	19	8
medical	1449	80	33	1200	47	1449	75	<b>31</b>	1200	45
cal500	68	68	5	68	4	68	68	2	68	<b>1</b>
genbase	1186	28	<b>13</b>	97	26	1186	29	14	97	26
mediamill	120	81	75	120	96	120	94	<b>72</b>	120	91
enron	1001	303	86	1001	96	1001	374	<b>78</b>	1001	86
bookmarks	2150	450	<b>56</b>	2150	92	2150	453	57	2150	93
bibtex	1836	171	<b>108</b>	1836	133	1836	169	109	1836	131
avg rank	9	5	<b>2</b>	8	4	9	5	<b>2</b>	8	3

**Tabela** : Liczba wybranych zmiennych. Parametr  $\lambda$  wybrany za pomocą BIC. Pogrubione liczby odpowiadają najlepszej metodzie.

# Eksperymenty

Dataset	CClogit	CCtree	CCnet ( $\alpha = 1$ )	CCnet ( $\alpha = 0$ )	CCnet ( $\alpha = 0.5$ )	BRlogit	BRtree	BRnet ( $\alpha = 1$ )	BRnet ( $\alpha = 0$ )	BRnet ( $\alpha = 0.5$ )
music	0.96	0.59	0.55	0.94	0.47	<b>0.25</b>	0.54	0.61	0.74	0.56
yeast	3.57	5.69	3.06	4.32	3.75	<b>1.85</b>	7.50	3.33	4.43	3.38
scene	23.98	8.25	<b>2.08</b>	7.97	3.08	20.44	8.45	2.39	8.05	3.64
birds	7.94	2.18	1.18	3.22	1.29	7.68	2.18	<b>0.94</b>	3.72	1.43
flags	0.05	0.09	0.24	0.40	0.28	<b>0.04</b>	0.09	0.26	0.34	0.29
medical	1426.40	12.49	<b>5.45</b>	19.89	5.63	1419.75	11.40	5.59	20.54	5.48
cal500	0.24	0.91	0.66	1.05	0.71	<b>0.21</b>	1.31	0.63	1.04	0.67
genbase	1254.63	6.35	2.97	3.16	2.86	1257.29	6.03	<b>2.60</b>	3.31	2.78
mediamill	18.16	28.22	6.60	20.53	8.82	9.37	35.58	<b>6.07</b>	20.50	7.72
enron	197.43	25.30	8.19	44.82	10.37	188.95	28.81	<b>7.95</b>	42.51	11.43
bookmarks	3370.57	246.90	50.34	391.62	58.44	3100.20	249.42	<b>47.61</b>	385.67	58.53
bibtex	4911.14	209.11	70.49	525.61	82.10	5019.62	210.31	<b>67.61</b>	520.32	77.41
avg rank	7.46	6.62	2.77	7.62	4.15	5.77	6.85	<b>2.54</b>	7.38	3.85

Tabela : Czas budowy modelu. Parametr  $\lambda$  wybrany za pomocą BIC.  
Pogrubione liczby odpowiadają najlepszej metodzie.



# Eksperymenty

## Wnioski:

1. CCnet (z dowolną  $\alpha$ ) osiąga większą dokładność zbioru niż inne metody.
2. Wartość  $\alpha$  nie ma bardzo dużego wpływu na dokładność i miarę Hamminga. Wartość  $\alpha > 0$  jest zalecana ze względu na selekcję zmiennych.
3. BRnet osiąga największe wartości miary Hamminga.
4. Kara lasso (BRnet,  $\alpha = 1$  oraz CCnet,  $\alpha = 1$ ) pozwala na wybór najmniejszej liczby zmiennych.
5. Najmniejsze czasy dopasowania modelu obserwujemy dla kary lasso (BRnet,  $\alpha = 1$  oraz CCnet,  $\alpha = 1$ ).

Dziękuję za uwagę!