

# Regresiona Gausova uslovna slučajna polja

Mladen Nikolić

Grupa za mašinsko učenje i primene  
Matematički fakultet  
Univerzitet u Beogradu

Pregled

CCRF

GCRF

FF-GCRF

Pregled

CCRF



GCRF

FF-GCRF

## Uslovna nezavisnost promenljivih

- ▶ Promenljive  $y_1$  i  $y_2$  su uslovno nezavisne pri uslovu  $x$  ukoliko važi  
$$P(y_1, y_2|x) = P(y_1|x)P(y_2|x)$$
- ▶ Ovo je slabija relacija od pune nezavisnosti

# Uslovna nezavisnost promenljivih



## Uslovna nezavisnost promenljivih

- ▶ Uobičajena pretpostavka mašinskog učenja je da su opažanja nezavisna i jednako raspodeljena (eng. IID)
- ▶ Ova nezavisnost se prilikom modelovanja ogleda u činjenici da je model  $y = f(x)$  funkcija vektora atributa  $x$  i da time za neko konkretno  $x_i$ ,  $y_i$  zavisi samo od tog  $x_i$ , ali ne i od drugih  $y_j$  za  $j \neq i$
- ▶ Odnosno,  $P(y_1, \dots, y_n | x_1, \dots, x_n) = \prod_{i=1}^n P(y_i | x_i)$
- ▶ Koliko je ovo realistično?

# Realističnost nezavisnosti promenljivih

- ▶ Promene temperature vazduha
- ▶ Rasprostiranje supstanci u zemljištu
- ▶ Kupovina proizvoda
- ▶ Citiranje naučnih radova

# Uslovna slučajna polja (CRF)

- ▶ Diskriminativni model
- ▶ Modeluju  $P(y_1, \dots, y_n | x_1, \dots, x_n)$  ne pretpostavljajući faktorizaciju na pojedinačne verovatnoće, već u skladu sa grafom zavisnosti između promenljivih
- ▶ Polazne formulacije su bile klasifikacione, ali postoje i regresione




## Neprekidna uslovna slučajna polja (CCRF)

- ▶ Neprekidna uslovna slučajna polja:

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(\mathbf{x}, \boldsymbol{\alpha}, \boldsymbol{\beta})} \exp \left( \sum_{i=1}^N A(\boldsymbol{\alpha}, y_i, \mathbf{x}) + \sum_{i \sim j} I(\boldsymbol{\beta}, y_i, y_j, \mathbf{x}) \right)$$

gde  $i \sim j$  označava povezanost promenljivih  $y_i$  i  $y_j$  u grafu zavisnosti



# Neprekidna uslovna slučajna polja (CCRF)

- ▶ Predviđanje:

$$\hat{\mathbf{y}} = \arg \max_{\mathbf{y}} P(\mathbf{y}|\mathbf{x})$$

- ▶ Učenje:

$$L(\boldsymbol{\alpha}, \boldsymbol{\beta}) = \log P(\mathbf{y}|\mathbf{x})$$

$$(\hat{\boldsymbol{\alpha}}, \hat{\boldsymbol{\beta}}) = \arg \max_{\boldsymbol{\alpha}, \boldsymbol{\beta}} L(\boldsymbol{\alpha}, \boldsymbol{\beta})$$

pri čemu je moguće dodati i regularizaciju po parametrima  $\boldsymbol{\alpha}$  i  $\boldsymbol{\beta}$

## Atributske funkcije

- ▶ Kako izabrati funkcije  $A$  i  $I$ ?

$$A(\boldsymbol{\alpha}, y_i, \mathbf{x}) = \sum_{k=1}^K \alpha_k f_k(y_i, \mathbf{x})$$

$$I(\boldsymbol{\beta}, y_i, y_j, \mathbf{x}) = \sum_{l=1}^L \beta_l g_l(y_i, y_j, \mathbf{x})$$

- ▶ Za proizvoljne izbore atributskih funkcija  $f_k$  i  $g_k$ , trening i predviđanje mogu biti računski vrlo zahtevni

Pregled

CCRF

GCRF

FF-GCRF

## Gausova uslovna slučajna polja (GCRF)

- ▶ Ukoliko su  $f_k$  i  $g_k$  kvadratne funkcije,  $P(\mathbf{y}|\mathbf{x})$  je višedimenzionalna Gausova raspodela!
- ▶ Gausova raspodela se lako ocenjuje, a predviđanje se svodi na izračunavanje proseka
- ▶ Kako izabrati funkcije  $f_k$  i  $g_k$  na koristan način?

## Izbor atributskih funkcija

- ▶ Neka su dati modeli  $R_{ik}(\mathbf{x})$ ,  $k = 1, \dots, K$  modeli koji predviđaju  $y_i$  za  $i = 1, \dots, N$  i grafovi zavisnosti  $G_l$ ,  $l = 1, \dots, L$
- ▶ Onda možemo definisati

$$f_k(y_i, \mathbf{x}) = -(y_i - R_{ik}(\mathbf{x}))^2, \quad k = 1, \dots, K$$

$$g_l(y_i, y_j, \mathbf{x}) = -e_{ij}^l S_{ij}^l(\mathbf{x})(y_i - y_j)^2$$

pri čemu važi

$$e_{ij}^l = \begin{cases} 1, & (i, j) \in G_l \\ 0, & \text{inače} \end{cases}$$

## Gausova uslovna slučajna polja

- ▶ Puna forma:

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(\mathbf{x}, \boldsymbol{\alpha}, \boldsymbol{\beta})} \exp \left( - \sum_{i=1}^N \sum_{k=1}^K \alpha_k (y_i - R_{ik}(\mathbf{x}))^2 - \sum_{i \sim j} \sum_{l=1}^L \beta_l e_{ij}^l S_{ij}^l(\mathbf{x}) (y_i - y_j)^2 \right)$$

- ▶ Pojednostavljena forma:

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(\mathbf{x}, \alpha, \beta)} \exp \left( - \sum_{i=1}^N \alpha (y_i - R_i(x_i))^2 - \sum_{i \sim j} \beta S_{ij} (y_i - y_j)^2 \right)$$

## Gausova forma

- ▶ Treba upariti:

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(\mathbf{x}, \boldsymbol{\alpha}, \boldsymbol{\beta})} \exp \left( - \sum_{i=1}^N \sum_{k=1}^K \alpha_k (y_i - R_{ik}(\mathbf{x}))^2 - \sum_{i \sim j} \sum_{l=1}^L \beta_l e_{ij}^l S_{ij}^l(\mathbf{x}) (y_i - y_j)^2 \right)$$

i

$$-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu}) = -\frac{1}{2}\mathbf{y}^T \boldsymbol{\Sigma}^{-1}\mathbf{y} + \mathbf{y}^T \boldsymbol{\Sigma}^{-1}\boldsymbol{\mu} + \text{const}$$



## Gausova forma

$$\Sigma_{ij}^{-1} = \begin{cases} 2 \sum_{k=1}^K \alpha_k + 2 \sum_{k=1}^K \sum_{l=1}^L \beta_l e_{ik}^l S_{ik}^l(\mathbf{x}) & i = j \\ -2 \sum_{l=1}^L \beta_l e_{ij}^l S_{ij}^l & i \neq j \end{cases}$$

$$\boldsymbol{\mu} = \boldsymbol{\Sigma} \mathbf{b}$$

$$b_i = 2 \left( \sum_{k=1}^K \alpha_k R_{ik}(\mathbf{x}) \right)$$

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{(2\pi)^{N/2} |\boldsymbol{\Sigma}|^{1/2}} \exp \left( -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right)$$

## Gausova forma

- ▶ Da li je  $\Sigma^{-1}$  pozitivno semi-definitna matrica?
- ▶ Da bi bila, dovoljno je da bude dijagonalno dominantna
- ▶ To važi ako je  $\alpha_k > 0$  i  $\beta_l > 0$  za svako  $k$  i  $l$
- ▶ Ovim se metod ograničava!
- ▶ Postoji unapređenje koje otklanja ovo ograničenje

# Predviđanje

- ▶ Predviđanje se daje prosekom Gausove raspodele

$$\hat{\mathbf{y}} = \arg \max_{\mathbf{y}} P(\mathbf{y}|\mathbf{x}) = \mathbf{\Sigma} \mathbf{b}$$

# Predviđanje

- ▶ Predviđanje se daje prosekom Gausove raspodele

$$\hat{\mathbf{y}} = \arg \max_{\mathbf{y}} P(\mathbf{y}|\mathbf{x}) = \mathbf{\Sigma} \mathbf{b}$$

- ▶ Za predviđanje je potrebno uraditi inverziju matrice  $\mathbf{\Sigma}^{-1}$ , što je računski skuplje nego predviđanja klasičnih metoda

- ▶ Potrebno je izračunati parcijalne izvode po  $\alpha_k$  i  $\beta_l$  i primeniti gradijentni spust na  $-\log P(\mathbf{y}|\mathbf{x})$

$$\frac{\partial \log P}{\partial \alpha_k} = -\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \frac{\partial \boldsymbol{\Sigma}^{-1}}{\partial \alpha_k} (\mathbf{y} - \boldsymbol{\mu}) + \left( \frac{\partial \mathbf{b}^T}{\partial \alpha_k} - \boldsymbol{\mu}^T \frac{\partial \boldsymbol{\Sigma}^{-1}}{\partial \alpha_k} \right) (\mathbf{y} - \boldsymbol{\mu}) + \frac{1}{2} \text{Tr} \left( \boldsymbol{\Sigma} \frac{\partial \boldsymbol{\Sigma}^{-1}}{\partial \alpha_k} \right)$$

$$\frac{\partial \log P}{\partial \beta_k} = -\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \frac{\partial \boldsymbol{\Sigma}^{-1}}{\partial \beta_l} (\mathbf{y} - \boldsymbol{\mu}) + \frac{1}{2} \text{Tr} \left( \boldsymbol{\Sigma} \frac{\partial \boldsymbol{\Sigma}^{-1}}{\partial \beta_l} \right)$$

- ▶ Gradijentni spust neće garantovati da će  $\alpha_k$  i  $\beta_l$  biti strogo pozitivni
- ▶ Moguće je optimizovati po novim promenljivim  $u_k = \log \alpha_k$  i  $v_k = \log \beta_l$
- ▶ Jedna iteracija gradijentnog spusta košta  $O(N^3)$ , gde je  $N$  veličina trening skupa, zbog inverzije matrice  $\Sigma^{-1}$
- ▶ Ukoliko je matrica  $\Sigma^{-1}$  retka, onda je cena jedne iteracije  $O(N^2)$

## ► Predviđanje koncentracije aerosola u vazduhu

**Table 1.** RMSE and FRAC of C005, NN, and NN+CCRF using features defined over five regions, without ( $\beta = 0$ ) and with spatio-temporal correlation ( $\beta \neq 0$ )

Region	RMSE				FRAC			
	C005	NN	CRF, $\beta = 0$	CRF, $\beta \neq 0$	C005	NN	CRF, $\beta = 0$	CRF, $\beta \neq 0$
Whole Globe	0.123	0.112±0.001	0.1067±0.0005	0.1056±0.0005	0.65	0.667±0.002	0.704±0.003	0.708±0.004
N. America	0.098	0.085±0.001	0.083±0.001	0.081±0.001	0.64	0.667±0.008	0.71±0.01	0.71±0.01
S. America	0.140	0.110±0.005	0.104±0.003	0.098±0.002	0.55	0.56±0.01	0.58±0.02	0.60±0.02
Europe	0.080	0.080±0.001	0.0736±0.0005	0.0728±0.0005	0.76	0.762±0.005	0.807±0.006	0.812±0.006
Africa	0.172	0.154±0.001	0.152±0.001	0.149±0.001	0.53	0.560±0.006	0.568±0.007	0.577±0.006
Asia&Aus.	0.161	0.156±0.001	0.145±0.001	0.148±0.001	0.64	0.66±0.01	0.71±0.01	0.70±0.01

Pregled

CCRF

GCRF

FF-GCRF



## Slučaj gustih grafova zavisnosti

- ▶ Velika složenost učenja i predviđanja onemogućava primenu na gusto povezane grafove, odnosno probleme u kojima postoje zavisnosti među većinom promenljivih
- ▶ Šta raditi?

## Slučaj gustih grafova zavisnosti

- ▶ Velika složenost učenja i predviđanja onemogućava primenu na gusto povezane grafove, odnosno probleme u kojima postoje zavisnosti među većinom promenljivih
- ▶ Šta raditi?
- ▶ Aproksimacijama sniziti računsku složenost

## Teorija usrednjenog polja (eng. mean field theory)

- ▶ Problem interakcija velikog broja elemenata nekog sistema je po pravilu težak problem
- ▶ U fizici se kao rešenje koristi aproksimacija pri kojoj se uticaj svih pojedinačnih elemenata na jedan konkretan element zameni njihovim ukupnim uticajem (uprosecenim poljem) na taj element
- ▶ Kako tačno podesiti taj ukupni uticaj tako da rezultati budu dobri?
- ▶ Ovaj princip je više puta oktrivan i u drugim disciplinama

## Aproksimacija usrednjenim poljem (eng. mean field approximation)

- ▶ Neka je:

$$Q(\mathbf{y}|\mathbf{x}) = \prod_{i=1}^N Q_i(y_i|\mathbf{x})$$

- ▶ Pod tom pretpostavkom, rešiti

$$\min_Q D_{KL}(Q||P)$$

- ▶ Rešenje:

$$\log(Q_i(y_i|\mathbf{x})) = E_{y_1 \dots y_{i-1}, y_{i+1} \dots y_N}[\log P(\mathbf{y}|\mathbf{x})] + const$$

## Aproksimacija usrednjenim poljem (eng. mean field approximation)

- ▶ U slučaju GCRF-a, to daje:

$$\log(Q_i(y_i|\mathbf{x})) = -\sum_{k=1}^K \alpha_k (y_i^2 - 2y_i R_{ik}(\mathbf{x})) - 2 \sum_{l=1}^L \beta_l \sum_{i \neq j} S_{ij}^l(\mathbf{x}) (y_i^2 - 2y_i E[y_j]) + \text{const}$$

- ▶ Svaka  $Q_i(y_i|\mathbf{x})$  je Gausova raspodela sa parametrima:

$$\mu_i = \frac{\sum_{k=1}^K \alpha_k R_{ik}(\mathbf{x}) + 2 \sum_{l=1}^L \beta_l \sum_{j \neq i} S_{ij}^l(\mathbf{x}) \mu_j}{\sum_{k=1}^K \alpha_k + 2 \sum_{l=1}^L \beta_l \sum_{j \neq i} S_{ij}^l(\mathbf{x})}$$
$$\sigma_i^2 = \frac{1}{2 \left( \sum_{k=1}^K \alpha_k + 2 \sum_{l=1}^L \beta_l \sum_{j \neq i} S_{ij}^l(\mathbf{x}) \right)}$$

- ▶ Složenost iterativnog određivanja  $\mu_i$  je  $O(IN^2)$  pri pretpostavci  $I \ll N$  za broj iteracija
- ▶ Složenost računanja varijansi je  $O(N^2)$

## Gausov kernel

- ▶ Neka je

$$S_{ij}^l(\mathbf{x}) = k_l(p_i^l, p_j^l) = \exp\left(-\frac{1}{2}(p_i^l - p_j^l)^T \Lambda_l (p_i^l - p_j^l)\right)$$

gde je  $p_i^l$  skup atributa instance  $i$  u nekom prostoru (koji može zavistiti od  $l$ ), a  $\Lambda_l$  simetrična pozitivno definitna matrica

- ▶ Sume koje uključuju sličnost se sada mogu zapisati kao:

$$\sum_{j \neq i} S_{ij}^l(\mathbf{x}) \mu_j = \sum_j k_l(p_i^l, p_j^l) \mu_j - \mu_i$$

$$\sum_{j \neq i} S_{ij}^l(\mathbf{x}) = \sum_j k_l(p_i^l, p_j^l) \mu_j - 1$$

# Konvolucija sa Gausovim kenrelom

- ▶ Ključni posao je izračunati konvoluciju:

$$\sum_j k_l(p_i^l, p_j^l) \mu_i$$

koja se naivno računa u vremenu  $O(N^2)$

- ▶ Postoje efikasne aproksimacije!

## Brza konvolucija sa Gausovim kernelom

- ▶ Konstruisati regularnu rešetku (postoje različiti modeli) koja pokriva prostor nad kojim je definisan kernel
- ▶ Konvolucija na rešetci samo sa bliskim susedima se računa u vremenu  $O(d^2 N)$  gde je  $d$  dimenzija vektora  $p_i^j$ , ali samo ukoliko se radi sa kernelom čija je matrica  $\Lambda_l$  identička
- ▶ Šta činiti?




## Brza konvolucija sa Gausovim kernelom

- ▶ Dekomponovati  $\Lambda_l = U^T U$  Čoleski dekompozicijom (dimenzija  $\Lambda_l$  je mala u odnosu na broj promenljivih)


$$\begin{aligned}k_l(p_i^l, p_j^l) &= \exp\left(-\frac{1}{2}(p_i^l - p_j^l)^T U^T I U (p_i^l - p_j^l)\right) \\ &= \exp\left(-\frac{1}{2}(Up_i^l - Up_j^l)^T I (Up_i^l - Up_j^l)\right)\end{aligned}$$

- ▶ Očito, primena polaznog kernela nad vektorima  $p_i^l$  je isto što i primena kernela sa identičkom matricom nad vektorima  $Up_i^l$
- ▶ Transformisati sve  $p_i^l$  u  $Up_i^l$  i projektovati na temena rešetke
- ▶ Uraditi konvoluciju sa Gausovim kernelom pretpostavljajući nezavisnost duž pravaca rešetke, a uzimajući u obzir samo temena u nekoj uskoj okolini
- ▶ Aproksimirati vrednosti konvolucije u tačkama  $Up_i^l$  na osnovu vrednosti na rešetci


# Brza konvolucija sa Gausovim kernelom



Splat



Blur



Slice

# Predviđanje

- ▶ Predviđanje

$$y_i = \arg \max_y Q_i(y|\mathbf{x}) = \mu_i$$

- ▶ Korišćenjem brze konvolucije, složenost je  $O(ld^2N)$
- ▶  $l$  je fiksirano na primer na 200

- ▶ Neka je:

$$\mathcal{L}(\boldsymbol{\alpha}, \boldsymbol{\beta}) = \log P(\mathbf{y}|\mathbf{x})$$

- ▶ Važi:

$$\frac{\partial \mathcal{L}(\boldsymbol{\alpha}, \boldsymbol{\beta})}{\partial \alpha_k} = \sum_{i=1}^N (E_Q[(y_i - R_{ik}(\mathbf{x}))^2] - (y_i - R_{ik}(\mathbf{x}))^2)$$

$$\frac{\partial \mathcal{L}(\boldsymbol{\alpha}, \boldsymbol{\beta})}{\partial \beta_l} = \sum_{i=1}^N \sum_{i \neq j} k_l(p_i^l, p_j^l) (E_Q[(y_i - y_j)^2] - (y_i - y_j)^2)$$

- ▶ Ispostavlja se da se brzom konvolucijom gradijent računa u vremenu  $O((ld^2 + K + Lld^2)N)$

- Predviđanje koncentracije aerosola u vazduhu

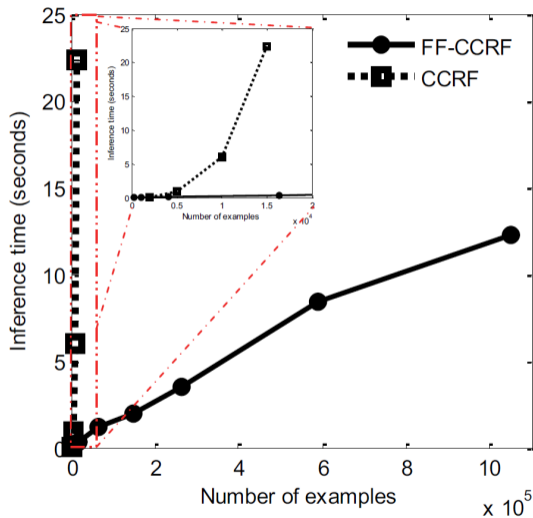
Table 1: Root mean squared error (RMSE) of fast fully connected CRF (FF-CCRF), fully-connected CCRF, and domain-knowledge based algorithm (C005) for aerosol optical depth prediction on different test set sizes  $N$ .

SIZE	$N = 3,000$	$N = 20,000$
FF-CCRF	<b><math>0.117 \pm 0.001</math></b>	<b><math>0.115 \pm 0.005</math></b>
C005	$0.126 \pm 0.010$	$0.129 \pm 0.010$
CCRF	<b><math>0.116 \pm 0.001</math></b>	N/A

- Uklanjanje šuma sa slika

Table 2: Average root mean squared error (RMSE) over 68 test images as result of denoising by FF-CCRF and NLM (lower RMSE is better).

NOISE LEVEL	10	15	20	25
NLM	6.20	8.11	9.39	10.68
FF-CCRF	<b>6.05</b>	<b>7.85</b>	<b>9.17</b>	<b>10.43</b>



## Literatura

- ▶ V. Radosavljević, S. Vučetić, Z. Obradović, Continuous Conditional Random Fields for Regression in Remote Sensing
- ▶ V. Radosavljević, S. Vučetić, Z. Obradović, Neural Gaussian Conditional Random Fields
- ▶ K. Ristovski, V. Radosavljević, S. Vučetić, Z. Obradović, Continuous Conditional Random Fields for Efficient Regression in Large Fully Connected Graphs
- ▶ A. Adams, J. Baek, M. A. Davis, Fast High-Dimensional Filtering Using the Permutohedral Lattice
- ▶ P. Krähenbühl, V. Koltun, Efficient Inference in Fully Connected CRFs with Gaussian Edge Potentials
- ▶ J. Glass, M. Ghalwash, M. Vukićević, Z. Obradović, Extending the Modelling Capacity of Gaussian Conditional Random Fields while Learning Faster

HVALA NA PAŽNJI!