


**ELEKTRONIKAS UN
DATORZINĀTŅU
INSTITŪTS**



**INSTITUTE OF
ELECTRONICS AND
COMPUTER SCIENCE**

Informatīvo spektra joslu izvēle hiperspektrālo attēlu klasifikācijai

Mg.math. Juris Siņica – Siņavskis

Dr.habil.math. Aivars Lorencs

Dr.sc.comp. Ints Mednieks

VPP projekta Nr.4 "GUDPILS" seminārs par 2. etapa
rezultātiem

16.03.2016.

Saturs

- Ievads – kas ir hiperspektrālie attēli?
- Problēma – datu apjoms
- Hiperspektrālais *Indian Pines* attēls
- Piedāvātā pieeja
 - spektrālo joslu izvēles procedūra
 - procedūras papildinājums
- klasifikācija ar diviem klasifikatoriem
(Beijesa un SVM)


Hiperspektrālie attēli

Ūdens tilpne

Lauksaimniecības
zeme

Hiperspektrālais sensors –
elektromagnētiskās enerģijas sensors ar kura
palīdzību iegūst datus jeb attēlus par noteiktu
apgabalu redzamās, tuvās infrasarkanās,
termālās spektra joslās
(ļoti daudzās, pēc attāluma tuvos
elektromagnētisko viļņu
garumos) ar skaitu vairāk nekā 30.

Hiperspektrālais sensors




Meži

Mājas

Ceļš

Hiperspektrālie attēli un problēma

Daudzdimensionālo datu apjoms ietekmē datu apstrādes ātrdarbību, pārsūtīšanu un glabāšanu



Hjūza (Hough) fenomens

Pieaugot dimensiju skaitam, kategoriju klasifikācijas precizitāte krītas un svārstās, ko sauc par dimensijas lāstu (*Curse of dimensionality*, Richard E. Bellman, 1920).





Fig. 4. Finite data set accuracy ($p_{cl} = \frac{1}{2}$).

Informatīvās spektrālās joslas

Kā izvēlēties informatīvo spektrālo joslu komplektu, ko tālāk izmantot klasifikācijas uzdevumam?

Vidējās vērtības pikseļiem **220** spektrālās joslās




hiperspektrālā attēla vizualizācija, izvēloties zilās joslas kanālu **26**, zaļās joslas kanālu **68** un sarkanās joslas kanālu **121**




Informatīvās spektrālās joslas

Kā izvēlēties informatīvo spektrālo joslu komplektu, ko tālāk izmantot klasifikācijas uzdevumam?

Vidējās vērtības pikseļiem **220** spektrālās joslās



hiperspektrālā attēla vizualizācija, izvēloties zilās joslas kanālu **46**, zaļās joslas kanālu **90** un sarkanās joslas kanālu **175**



Indian Pines hiperspektrālais attēls

Hiperspektrālā attēla vizualizācija,
B = 40, G = 30, R = 20

Zināmi $K=16$ kategoriju pikseļu izvietojumi



Indian Pines hiperspektrālais attēls

Sensora AVIRIS dati *Indian Pines*

Zemas izšķirtspējas hiperspektrālais attēls iegūts *Indian Pines* apvidū ziemeļrietumos Indianas štatā (ASV) 1992. gadā veģetācijas periodā, kurā ir jaukta lauksaimniecības un mežu teritorija.

Hiperspektrālā attēla izmērs ir **145 x 145** pikseļi,
220 spektrālās joslas **0.4 - 2.5 μm** viļņu garumos.

Spektrālā izšķirtspēja **10 nm**

Telpiskā izšķirtspēja **20 m**

Radiometriskā izšķirtspēja ir **16 biti**

Joslu izvēles procedūra

Pieņēmumi

patvaļīgs **pikselis** $\vec{p} = (a_1, a_2, \dots, a_N)^T$, kur a_j ir j -tās joslas starojuma intensitātes vērtības mērskaaitlis. **Gadījumlielumam** X_j (katras spektrālās joslas intensitātes vērtību kopumam) tieši j -tajai joslai eksistē galīga **vidējā vērtība** $\mu_j = EX_j$ un galīga **dispersija** $\sigma_j = DX_j$

Definīcija

$H(X_i) = - \int_{-\infty}^{\infty} f_i(x) \log(f_i(x)) dx$ ir i -tās joslas **entropija**, kur $f_i(x)$ gadījumlieluma sadalījuma blīvumfunkcija.

Informatīvu joslu komplektu izvēles procedūra (pie fiksēta skaita k , $k \ll N$)

1. Joslu i_1 definējam kā joslu ar vislielāko entropijas vērtību;
2. Visām joslām $i \neq i_1$ aprēķinām $\text{cov}(X_i, X_{i_1})$ un atrodam joslu, kurai ir vislielākā vērtība attiecībai

$\frac{H(X_i)}{\text{cov}(X_i, X_{i_1})}$; šo joslas indeksu i definējam kā i_2 , kuru iekļaujam komplektā;

Joslu izvēles procedūra

Informatīvu joslu komplektu izvēles procedūra (pie fiksēta skaita $k, k \ll N$)

3. Aprēķinām $\text{cov}(X_i, X_{i_2})$ visiem $i \neq i_2$ un $i \neq i_1$; joslu i_3 definējam kā joslu ar vislielāko vērtību summai $\frac{H(X_i)}{\text{cov}(X_i, X_{i_1})} + \frac{H(X_i)}{\text{cov}(X_i, X_{i_2})}$;
4. Ja pirmās ν joslas $i_1, i_2, \dots, i_\nu$ izvēlētas, bet $\nu < k$, tad $\nu + 1$ joslu definējam kā joslu i , pie kura dabūjam vislielāko vērtību summai

$$\frac{H(X_i)}{\text{cov}(X_i, X_{i_1})} + \frac{H(X_i)}{\text{cov}(X_i, X_{i_2})} + \dots + \frac{H(X_i)}{\text{cov}(X_i, X_{i_\nu})} .$$

Joslu izvēles procedūra

Problēma

Joslu izvēles procedūru neļauj efektīvi veikt ūdens absorbcijas un trokšņainās spektra joslas.

Risinājums

Ūdens absorbcijas joslas tiek izdzēstas, saskaņā ar *Feng* un līdzautoru darbu publikācijā [1].


Joslu nr. 104 105 106 107 108 150 151 152 153 154 155 156 157 158 159 160 161 162 163 220

Trokšņainās spektra joslas izdzēšam.

Korelācijas koeficienti starp blakus pikseļiem attēlā pa X un

Joslu nr. 1 2 3 36 37 77 78 79 80 81 82 83 84 85 86 87 88 89
90 91 92 93 94 95 96 97 98 99 100 103 104 105 144 145 199 200

pa Y asi katrā hiperspektrāla attēla joslā, to minimumi mazāki par sliekšni **0,82**, definē trokšņainās joslas.



1. Feng J., Jiao L. C., Zhang X., and Sun T., "Hyperspectral Band Selection Based on Trivariate Mutual Information and Clonal Selection," IEEE Trans. Geosci. Remote Sens., vol. 52, no. 7, pp. 4092–4105, 2014.

Joslu izvēles procedūra

Problēma

Joslu izvēles procedūru neļauj efektīvi veikt ūdens absorbcijas un trokšņainās spektra joslas.

Risinājums

Ūdens absorbcijas joslas tiek izdzēstas, saskaņā ar *Feng* un līdzautoru darbu publikācijā [1].

Joslu nr.

104	105	106	107	108	150	151	152	153	154	155	156	157	158	159	160	161	162	163	220
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

Trokšņainās spektra joslas izdzēšam.

Korelācijas koeficienti starp blakus pikseliem attēlā pa X un

Joslu nr.

1	2	3	36	37	77	78	79	80	81	82	83	84	85	86	87	88	89
90	91	92	93	94	95	96	97	98	99	100	103	104	105	144	145	199	200

pa Y asi katrā hiperspektrāla attēla joslā, to minimumi mazāki par sliekšni **0,82**, definē trokšņainās joslas.

Papildinājumi procedūrai

- i -tās joslas pikselis tiek standartizēts pēc formulas $\frac{X - \mu_i}{\sigma_i}$.
- Sākot ar joslu procedūras 3. soli, katra nākamā josla tiek pievienota komplektam ar nosacījumu, ja pikseļu šīs joslas **korelācija** ar iepriekš noteiktajām joslām absolūtā vērtība nepārsniedz sliekšni **0,98**. Šāds papildinājums procedūrai nepieciešams, lai neiekļautu vairākas **blakusjoslas** komplektā.

Piemēram, 15 joslas bez nosacījuma:


35	58	60	61	62	64	65	66	67	68	74	75	76	101	102
----	----	----	----	----	----	----	----	----	----	----	----	----	-----	-----

15 joslas ar nosacījumu:

4	5	6	15	30	34	35	38	47	58	62	101	112	135	179
---	---	---	----	----	----	----	----	----	----	----	-----	-----	-----	-----


1. Feng J., Jiao L. C., Zhang X., and Sun T., "Hyperspectral Band Selection Based on Trivariate Mutual Information and Clonal Selection," IEEE Trans. Geosci. Remote Sens., vol. 52, no. 7, pp. 4092–4105, 2014.

Joslu izvēles procedūras ilustrācija




Joslu izvēles procedūras ilustrācija


entropy, $i_{\max} = 62$




entropy vs cov, $i_1 = 62$, $i_{\max} = 35$




entropy vs cov, $i_2 = 35$, $i_{\max} = 65$




entropy vs cov, $i_3 = 38$, $i_{\max} = 101$



entropy vs cov, $i_4 = 101$, $i_{\max} = 58$




entropy vs cov, $i_5 = 58$, $i_{\max} = 59$




Joslu izvēles procedūras ilustrācija


entropy vs cov, $i_6 = 47$, $i_{\max} = 48$




entropy vs cov, $i_7 = 34$, $i_{\max} = 64$




entropy vs cov, $i_8 = 15$, $i_{\max} = 16$




entropy vs cov, $i_9 = 4$, $i_{\max} = 6$



entropy vs cov, $i_{10} = 6$, $i_{\max} = 61$




entropy vs cov, $i_{11} = 5$, $i_{\max} = 65$




Joslu izvēles procedūras ilustrācija


entropy vs cov, $i_{12} = 135$, $i_{\max} = 63$




entropy vs cov, $i_{13} = 30$, $i_{\max} = 57$




entropy vs cov, $i_{14} = 179$, $i_{\max} = 44$




entropy vs cov, $i_{15} = 112$, $i_{\max} = 61$



entropy vs cov, $i_{16} = 111$, $i_{\max} = 102$




entropy vs cov, $i_{17} = 165$, $i_{\max} = 66$




Joslu izvēles procedūras ilustrācija


entropy vs cov, $i_{15} = 112$, $i_{\max} = 61$




entropy vs cov, $i_{16} = 111$, $i_{\max} = 102$




entropy vs cov, $i_{17} = 165$, $i_{\max} = 66$




entropy vs cov, $i_{18} = 217$, $i_{\max} = 63$



entropy vs cov, $i_{19} = 216$, $i_{\max} = 214$



entropy vs cov, $i_{20} = 215$, $i_{\max} = 71$



Rezultāti ar Beijesa tipa un SVM klasifikatoriem, $k=15$

Joslu komplekts

62	35	38	101	58	47	34	15	4	6	5	135	30	179	112
----	----	----	-----	----	----	----	----	---	---	---	-----	----	-----	-----

joslas sakārtotas augošā secībā

4	5	6	15	30	34	35	38	47	58	62	101	112	135	179
---	---	---	----	----	----	----	----	----	----	----	-----	-----	-----	-----

Beijesa tipa klasifikācijas rezultāti

Kopējā precizitāte (OA) un precizitāte pa kategorijām (UA), 20% apmācībai

OA = 0,79

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	NaN	0,77	0,72	0,81	0,90	0,95	NaN	0,99	NaN	0,76	0,65	0,88	0,85	0,95	0,67	0,60

70% apmācībai

OA = 0,81

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,93	0,79	0,75	0,90	0,91	0,95	0,85	0,98	0,80	0,83	0,60	0,91	0,99	0,97	0,69	0,99

SVM klasifikācijas rezultāti

20% apmācībai

OA = 0,71

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,85	0,90	0,71	0,32	0,95	0,98	0,88	0,93	0,05	0,75	0,49	0,31	0,94	0,93	0,31	0,95

70% apmācībai

OA = 0,79

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,96	0,92	0,84	0,45	0,97	0,98	0,85	0,93	0,60	0,81	0,60	0,49	0,99	0,96	0,41	0,88

SVM klasifikācijas rezultāti ar publikācijā [2] doto joslu komplektu → OA=0,69

2. Sun K., Geng X., Ji L., and Lu Y., "A New Band Selection Method for Hyperspectral Image Based on Data Quality," IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens., vol. 7, no. 6, pp. 2697–2703, Jun. 2014.

Rezultāti ar Beijesa tipa un SVM klasifikatoriem, $k=20$

Joslu komplekts

62 35 38 101 58 47 34 15 4 6 5 135 30 179 112 111 165 217 216 215

joslas sakārtotas augošā secībā

4 5 6 15 30 34 35 38 47 58 62 101 111 112 135 165 179 215 216 217

Beijesa tipa klasifikācijas rezultāti

Kopējā precizitāte (OA) un precizitāte pa kategorijām (UA), 20% apmācībai

$OA = 0,79$

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	NaN	0,773	0,728	0,718	0,893	0,953	NaN	0,99	NaN	0,749	0,673	0,852	0,759	0,953	0,655	NaN

70% apmācībai

$OA = 0,82$

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,87	0,81	0,76	0,91	0,91	0,95	NaN	0,99	NaN	0,84	0,63	0,93	0,99	0,96	0,71	0,98

SVM klasifikācijas rezultāti

20% apmācībai

$OA = 0,74$


	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,65	0,89	0,75	0,35	0,93	0,98	0,73	0,94	0,15	0,76	0,56	0,38	0,93	0,95	0,35	0,97

70% apmācībai

$OA = 0,82$

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	K16
UA	0,98	0,94	0,87	0,47	0,97	0,99	0,92	0,96	0,90	0,83	0,65	0,57	0,99	0,97	0,51	0,92

Rezultāti ar Beijesa tipa un SVM klasifikatoriem



Paldies par uzmanību!

