

LATVIJAS UNIVERSITĀTE

DTF DOKTORANTU UN DOKTORANTŪRAS SKOLAS SEMINĀRS

Multidimensionālu datu apjoma ekvivalentas redukcijas pieejas objektu klasifikācijai

13.01.2016

2.k. doktorants:

Juris SIŅICA-SIŅAVSKIS

ELEKTRONIKAS UN
DATORZINĀTŅU
INSTITŪTS



INSTITUTE OF
ELECTRONICS AND
COMPUTER SCIENCE

Vadītājs:

Dr.sc.comp Ints MEDNIEKS

- ▶ Tēmas aktualitāte (State of the art)
izstrādātas daudzas metodes dimensiju samazināšanai [3], kas pamatā transformē datus uz citu reprezentāciju (PCA), kurā dimensiju skaitu var samazināt.
- ▶ Mūsu pieeja
izvēlēties informatīvo joslu komplektu, jo šeit pētījumi ir mazāk (nepietiekoši)
- ▶ Mērķis
samazināt dimensiju skaitu, nodrošinot klasifikācijas kvalitāti
- ▶ Uzdevumi
 - izpētīt jomu no literatūras;
 - piedāvāt metodes dimensiju skaita samazināšanai, saglabājot klasifikācijas kvalitāti;
 - pārbaudīt metodes uz dažādiem hiperspektrāliem datiem un salīdzināt rezultātus;

Promocijas darba tēmas pamatnostādnes

Multidimensionālu datu apjoma ekvivalentas redukcijas pieejas objektu klasifikācijai

1. Dimensiju redukcija ir procedūra, kurā n -dimensionālu attēlu kopumu transformē par k -dimensionālu attēlu kopumu ($k \ll n$).
2. Jābūt formulētai uzdevumu saimei, kuru veido problēmas, kas risināmas attiecībā uz šiem attēliem. Piemēram,
 - attēlos ir (vai nav) prezentēti noteiktas kategorijas objekti;
 - uzdevumi atrast algoritmu šo objektu detektēšanai. Šo kategoriju skaits parasti ir lielāks par 2. Var būt attēlu pikseļu klasifikācijas uzdevums par noteiktām kategorijām, vai pikseļu aplokšņu klasifikācijas uzdevums.
3. Ar ekvivalentu redukciju saprotam tādu redukcijas īpašību, ka problēmas atrisinājums, kas iegūstams uz neliela spektru joslu skaitu pamata, pēc savas kvalitātes ir tuvs vai līdzvērtīgs tam, ko var iegūt uz visu joslu informācijas bāzes. Kvalitātes kritērijs detektēšanas vai klasifikācijas gadījumā parasti ir pieļauto kļūdu procents.

Ievads

Pamatnostādnes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Promocijas darba tēmas pamatnostādnes

Multidimensionālu datu apjoma ekvivalentas redukcijas pieejas objektu klasifikācijai

4. Dimensiju redukcijas pirmajā etapā no atsevišķiem attēliem tiek iegūta informācija par spektra joslu komplektu informativitātes līmeni. Šī līmeņa noteikšanai var izvēlēties dažādus kritērijus.
5. Otrajā etapā tiek veidots klasifikators balstoties uz informatīvo joslu komplektu (IJK).
6. Dimensiju redukcijas rezultātā iegūstam datus, kuru apstrāde prasa krietni mazāku operāciju skaitu. Iespējams, ka vienkāršāka datu iegūšanas metodika, balstoties uz IJK, dotu iespēju jaunas aparatūras realizācijai.

Ievads

Pamatnostādnes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Literatūras pārskats

Lai sagatavotu literatūras pārskatu (LP), tika formulēts pētnieciskais jautājums:

kā izvēlēties spektrālo joslu komplektu, lai veiktu efektīvu klasifikāciju?

LP procesā tika iegūti **497** meklējuma rezultāti IEEEExplore publikāciju datubāzē pēc vairākiem atslēgas vārdiem, piem., *spectral band selection, channel selection, remote sensing, dimensional reduction, Hughes phenomenon, optimum index factor, optimum band selection*.

Pēc atslēgas vārdiem *spectral band selection* tika pārlasītas **55** publikācijas; *dimensional reduction* - **37** publikācijas. **11** publikāciju (S1-S11) saturs tika atzīts par atbilstošu pētnieciskā jautājuma formulējumam.

Ievads

Pamatnostādes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Literatūras pārskats


- S1. J. Feng, L. C. Jiao, X. Zhang, and T. Sun. Hyperspectral Band Selection Based on Trivariate Mutual Information and Clonal Selection, *IEEE Trans. on Geosc. and Rem. Sens.*, Vol. 52, No. 7, July 2014, pp. 4092-4105. ievads
- S2. K. Sun, X. Geng, L. Ji, and Y. Lu. 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. Pamatnostādes
- S3. H. Yang, Q. Du, H. Su, and Y. Sheng. An Efficient Method for Supervised Hyperspectral Band Selection. *IEEE Geosci. Remote Sens. Lett.*, Vol. 8, No. 1, pp. 138-142, 2011. Literatūras pārskats
- S4. H. Yang, Q. Du, and G. Chen. Unsupervised Hyperspectral Band Selection Using Graphics Processing Units, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, Vol. 4, No. 3, pp. 660-668, 2011. Indian Pines dataset
- S5. K. Tan, E. Li, Q. Du, and P. Du. Hyperspectral Image Classification Using Band Selection and Morphological Profiles, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 7, no. 1, pp. 40-48, 2014. GRSS piemērs
- S6. S. Jia, Z. Ji, Y. Qian, and L. Shen. Unsupervised Band Selection for Hyperspectral Imagery Classification without Manual Band Removal, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, Vol. 5, No. 2, pp. 109-112, 2012. Spektra joslu izvēle
- S7. C. Chang, S. Wang. Constrained Band Selection for Hyperspectral Imagery, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, Vol. 44, No. 6, pp. 1575-1585, 2006. klasifikators
- S8. C. A. I. Simin, Z. Rongqun, C. Wenling, and Y. Hui. Band Selection of Hyperspectral Images Based on Bhattacharyya Distance, *WSEAS Trans. on Inform. Sci. Applic.*, Vol. 6, No. 7, pp. 1165-1175, 2009. Rezultāti
- S9. Y. Yuan, G. Zhu, and Q. Wang. Hyperspectral Band Selection by Multitask Sparsity Pursuit, *IEEE Trans. Geosci. Remote Sens.*, Vol. 53, No. 2, pp. 631-644, 2015. Secinājumi
- S10. C. I. Chang, Qian Du, Tzu-Lung Sun, and Mark L. G. Althouse. A joint band prioritization and band decorrelation approach to band selection for hyperspectral image classification, *IEEE Trans. Geosci. Remote Sens.*, Vol. 37, No. 6, pp. 2631-2641, 1999. Literatūra
- S11. R. I. Faulconbridge, M. R. Pickering, and M. J. Ryan. Unsupervised band removal leading to improved classification accuracy of hyperspectral images," *Conferences in Research and Practice in Information Technology Series, ACSC.*, Vol. 48, 2006. Publikācijas

Literatūras pārskats

ID	Method	Sensor /data / spectral bands / spectral range	Total of remaining spectral bands	OA / total of categories	Year	Cited by
S1	semisupervised trivariate mutual information (STMI) - clonal selection algorithm (CSA)	AVIRIS / Indian pine / 220 / 0.2-2.4 μm ROSIS/ University of Pavia / 115 / 0.43-0.86 μm	20 103	83.7+/-1.1 / 16 94.6+/-0.6/9	2014	2
S2	minimum noise band selection (MNBS)	AVIRIS / Salinas / 220 / 0.2-2.4 μm AVIRIS / Indian pine / 220 / 0.2-2.4 μm	204 15	93.0+/-0.4 /16 0.75/16	2014	2
S3	minimum estimated abundance covariance (MEAC)	AVIRIS / Lunar lake / 220 / AVIRIS / Cuprite / 220 / HYDICE / Mall in Washington / 210 / 0.4-2.4 μm HYMAP/ Purdue Data / 128 /	30(15)	95.0/-	2011	43
S4	N-Finder	AVIRIS / Cuprite / 220 /	40(20)	-	2011	46
S5	Support vector machine, morphological profiles	ROSIS/ University of Pavia / 115 / 0.43-0.86 μm HYDICE / Mall in Washington / 210 / 0.4-2.4 μm AVIRIS / Salinas / 220 / 0.2-2.4 μm	10 14 -	70.66/9 94.17/6 83.21/16	2014	5
S6	discrete wavelet transform, automatic noise reduction	AVIRIS / Indian pine / 220 / 0.2-2.4 μm AVIRIS / Okavango delta / 242 / 0.4-2.5 μm	15 7(15)	96.4/ 16 97.65+/-0.38 /16 96.28+/-0.75/14	2012	29
S7	constrained energy minimization, constrained band selection	AVIRIS / Indian pine / 220 / 0.2-2.4 μm AVIRIS / Cuprite / 220 /	9 22	-	2006	122
S8	Bhattacharyya Distance	OMIS-I / China / 64 / 0.46-1.1 μm	3	68.8+/-0.3 / 5	2009	5
S9	multitask sparsity pursuit (MTSP)	AVIRIS / Indian pine / 220 / 0.2-2.4 μm ROSIS/ University of Pavia / 115 / 0.43-0.86 μm AVIRIS / Salinas / 220 / 0.2-2.4 μm	-	95.0/ -	2015	0
S10	minimum-misclassification canonical analysis (MMCA)	HYDICE / Mall in Washington / 210 / 0.4-2.4 μm	11	-	1999	169
S11	Bhattacharyya Distance	AVIRIS / 220 / 0.4-2.5 μm	83	80.0+/-10 / 11	2006	0

Indian Pines dataset

AVIRIS sensor hyperspectral image (false color composition) and reference map containing **16** mutually exclusive land-cover classes (right)



The first hyperspectral image used in experiments was collected by the AVIRIS sensor over the Indian Pines region in Northwestern Indiana in 1992. This scene, with a size of **145** lines by **145** samples, was acquired over a mixed agricultural/forest area, early in the growing season. The scene comprises **220** spectral channels in the wavelength range from **0.4** to **2.5 μm** , nominal spectral resolution of **10 nm**, moderate spatial resolution of **20 m** by pixel, and **16-bit** radiometric resolution.

Ievads

Pamatnostādes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti


Secinājumi

Literatūra

Publikācijas

GRSS konkursa piemērs- LWIR

Termālais attēls un 7 savstarpēji izslēdzošas kategorijas



[Ievads](#)

[Pamatnostādes](#)

[Literatūras
pārskats](#)

[Indian Pines
dataset](#)

[GRSS piemērs](#)

[Spektra joslu izvēle](#)

[klasifikators](#)

[Rezultāti](#)

[Secinājumi](#)

[Literatūra](#)

[Publikācijas](#)

Termālā attēla spektrālo joslu izvēle

Termālā attēla klasifikācijas uzdevuma risināšanai tika izvēlētas spektrālās joslas, izmantojot sekojošas metodes:

- ▶ maksimālā Entropija $\sum(p_i \cdot \log_2(p_i))$, kur p sadalījuma blīvumfunkcija (Shannon entropy);
- ▶ Optimālais indeksa faktors¹ (Optimum index factor, OIF);
- ▶ Entropija un OIF rādītāji deva 50 joslu skaita samazinājumu, tāpēc no atlikušajām 34 joslām tika veikta manuāla joslu izvēle (paņemta katra 4. josla);
- ▶ Gala rezultātā ieguvām spektrālo joslu komplektu:

$$C9 = [4, 14, 26, 36, 47, 57, 69, 78] .$$

1. Markand P. Oza. Selection of band combination for IRS data. *J. of the Indian Soc. of Rem. Sens.*, Vol. 17, Issue 2, pp. 23-26, June 1989 .

Ievads

Pamatnostādnēs

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi


Literatūra

Publikācijas

Joslu dispersijas un komplekti

Faktiski kovariācijmatricas Σ diagonāles elementi veido spektrālo joslu dispersijas, no kurām izvēloties lielākās dispersijas, izveidojām joslu kompleksus. Katrai kategorijai tika aprēķināta Σ_r , $r = 1, 2, \dots, 7$, un iegūti spektrālo joslu komplekti C1, C2, ..., C7. Komplekts C8 iegūts veicot šādu procedūru:

- apvieno visus pikselus no katras kategorijas vienā kopā,
- visiem pikseļiem aprēķina kovariācijmatricu,
- atrod lielākās dispersijas.



No.	Joslu komplekti (8 joslas)	K2 100%
		OA
C1	[1 2 3 44 45 47 51 53]	0.51
C2	[1 2 3 4 5 6 7 8]	0.49
C3	[1 2 3 4 6 7 8 21]	0.51
C4	[1 2 3 4 6 7 8 20]	0.49
C5	[1 2 3 6 7 8 14 20]	0.48
C6	[1 2 3 4 6 7 8 20]	0.49
C7	[1 2 3 4 5 6 8 11]	0.49
C8	[1 2 3 4 6 7 8 11]	0.50
C9	[4 14 26 36 47 57 69 78]	0.55

Ievads

Pamatnostādes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Beijesa tipa klasifikatora kārtula K2

Promocijas darbs galvenokārt orientēts uz tādu multidimensionālu datu apstrādi, kuru sadalījuma deskripcijai praktiski var piemērot Gausa jeb normālā sadalījuma modeli.

$\mathbf{X} = (X_1, X_2, \dots, X_p)^T$ - p -dimensionāls normāli sadalīts gadījumu vektors ar vidējo vērtību

$\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_p)^T$ un $p \times p$ kovariācijmatricu

$\boldsymbol{\Sigma} = E(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T$,

tad šī vektora **varbūtību sadalījuma blīvumfunkcija**

$$f_{\mathbf{X}}(\mathbf{x}) = (2\pi)^{-p/2} |\boldsymbol{\Sigma}|^{-1/2} \exp(-1/2(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})).$$

Pieņem, ka attēlā katru pikseli reprezentē p spektra joslu intensitātes vektors $\mathbf{x} = (x_1, x_2, \dots, x_p)^T$, un attēlā fiksētas r dažādas pikseļu kategorijas. Tad mēs varam izveidot Beijesa tipa klasifikācijas kārtulu K2:

Pikseli $\mathbf{x}$ klasificēsim kā k -tās kategorijas pikseli tad un tikai tad, ja visiem $j = 1, \dots, r$

$$f_k(\mathbf{x})/f_j(\mathbf{x}) \geq 1.$$

Ievads

Pamatnostādnēs

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators


Rezultāti

Secinājumi

Literatūra

Publikācijas

Joslu dispersijas



ievads

Pamatnostādes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Informatīvo joslu komplekti (IJK)

IJK: C1-C16 (kategorijai atsevišķi); C17 (visām kategorijām); K.Sun IJK: C18

Beijesa tipa klasifikators K2, kur a – 70% apmācībai, b – 20% apmācībai

No.	Joslu komplekti (15 joslas)	SVM 20% OA	SVM 70% OA	K2a 70% OA	K2b 20% OA
C1	[1 24 25 26 27 28 29 30 32 48 49 50 51 52 53]	0.42	0.42	-	-
C2	[21 22 23 24 25 26 27 28 29 30 31 32 33 34 38]	0.44	0.50	0.66	0,62
C3	[23 24 25 26 27 28 29 33 34 37 38 39 41 42 43]	0.46	0.52	0.63	0,59
C4	[21 22 23 24 25 26 27 28 29 30 31 32 33 34 35]	0.38	0.40	0.59	0,56
C5	[38 39 41 42 43 44 45 46 47 48 49 50 51 52 53]	0.26	0.30	0.49	0,44
C6	[38 39 41 42 43 44 45 46 47 48 49 50 51 52 53]	0.26	0.30	0.49	0,44
C7	[1 38 39 41 42 43 44 45 46 48 49 50 51 52 53]	0.27	0.32	-	-
C8	[34 38 39 41 42 43 44 45 47 48 49 50 51 52 53]	0.40	0.45	0.57	0,51
C9	[1 28 29 38 39 41 42 43 44 45 47 48 49 50 53]	0.42	0.49	-	-
C10	[22 23 24 25 26 27 28 29 30 32 33 38 39 41 42]	0.42	0.47	0.60	0,57
C11	[23 24 25 26 27 28 29 30 32 33 34 38 39 41 42]	0.46	0.51	0.62	0,59
C12	[22 23 24 25 26 27 28 29 30 31 32 33 34 38 42]	0.46	0.51	0.65	0,62
C13	[1 25 26 27 28 29 32 33 34 39 41 42 43 44 45]	0.46	0.51	0.62	0,57
C14	[38 39 41 42 43 44 45 46 47 48 49 50 51 52 53]	0.26	0.30	0.49	0,44
C15	[38 39 41 42 43 44 45 46 47 48 49 50 51 52 53]	0.26	0.30	0.49	0,44
C16	[28 29 34 38 39 41 42 43 44 48 49 50 51 52 53]	0.49	0.55	-	-
C17	[22 23 24 25 26 27 28 29 30 31 32 33 41 42 43]	0.42	0.46	0.63	0.59
C18	[9 17 18 28 37 52 58 64 75 82 84 120 133 168 181]	0.70	0.74	0.80	0.77

Secinājumi un turpmākie darbi

1. Informatīvo joslu komplekta iegūšanas procedūra jāpapildina ar papildus kritēriju, veicot padziļinātu literatūras (publikāciju [8, 9]) analīzi;
2. Jāveic papildus eksperimenti ar dažādiem hiperspektrāliem attēliem, izmēģinot vairākas klasifikācijas kārtulas;
3. Jāiesniedz publikācija par veiktajiem pētījumiem;
4. Jāizstrādā promocijas darba melnraksts.

Ievads

Pamatnostādnes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas

Izmantotā literatūra

1. R. Neher and A. Srivastava. A Bayesian MRF Framework for Labeling Terrain Using Hyperspectral Imaging, *IEEE Trans. on Geosc. and Rem. Sens.*, Vol.43, No.6, pp. 1363 - 1374, 2005.
2. J. Feng, L. C. Jiao, X. Zhang, and T. Sun. Hyperspectral Band Selection Based on Trivariate Mutual Information and Clonal Selection, *IEEE Trans. on Geosc. and Rem. Sens.*, Vol. 52, No. 7, July 2014, pp. 4092-4105.
3. Van der Maaten, L., Postma, E., & van den Herik, J. Dimensionality Reduction: A Comparative Review. *Journal of Machine Learning Research*, pp. 1–41, 2009.
4. P. Bajorski. *Statistics for Imaging, Optics, and Photonics*, Wiley, 2012.
5. T. Lillesand, R. W. Kiefer, J. Chipman. *Remote Sensing and Image Interpretation.*, Wiley, 6th ed., 2008.
6. D. A. Landgrebe. *Signal Theory Methods in Multispectral Remote Sensing*, Wiley, 2003.
7. Chein-I Chang. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*, Kluwer Academic/Plenum, 2003.
8. K. Sun, X. Geng, L. Ji, and Y. Lu. 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.
9. C. I. Chang, Qian Du, Tzu-Lung Sun, and Mark L. G. Althouse. A joint band prioritization and band decorrelation approach to band selection for hyperspectral image classification, *IEEE Trans. Geosci. Remote Sens.*, Vol. 37, No. 6, pp. 2631–2641, 1999.

Literatūra

Autora raksti recenzētos izdevumos

1. A. Lorencs, I. Mednieks, J. Sinica-Sinavskis, "Fast Object Detection in Digital Grayscale Images," Proceedings of the Latvian Academy of Sciences, Section B., Vol.63, No.3, pp. 116-124, 2009.
2. A. Lorencs, I. Mednieks, J. Sinica-Sinavskis, "Design problems of tree species classifiers for multispectral images," Automatic Control and Computer Sciences, Vol. 45, No. 2, pp. 61-69, 2011.
3. R. Dinuls, G. Erins, A. Lorencs, I. Mednieks, and J. Sinica-Sinavskis, "Tree species identification in mixed Baltic forest using LiDAR and multispectral data," IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens., vol. 5, no. 2, pp. 594-603, 2012.
4. A. Lorencs, Yu. Sinita-Sinyavskis. "A two-stage method for building classifiers," Automatic Control and Computer Sciences, September 2012, Volume 46, Issue 5, pp. 214-222. 45, No. 2, pp. 61-69, 2012.
5. A.Lorencs, J.Sinica-Sinavskis, "Analysis of two-stage Bayes classifiers construction method: 2-dimensional case," Automatic Control and Computer Sciences, September 2013, Volume 47, No. 5, pp. 254-266, 2013.
6. A. Lorencs, I.Mednieks, J. Sinica-Sinavskis, " Simplified Classification of Multispectral Image Fragments,"18th international conference ELECTRONICS, Palanga, Lithuania, June 16-18, 2014.
7. A. Lorencs, I.Mednieks, J. Sinica-Sinavskis, " Classification of Multisensor Images With Different Spatial Resolution", Electronics and Electrical Engineering, Vol. 21, No. 5, pp. 81-85, 2015.
8. A.Lorencs, J.Sinica-Sinavskis, D.Jakovels, I.Mednieks, " Melanoma-Nevus Discrimination Based on Image Statistics in Few Spectral Channels", Electronics and Electrical Engineering, ISSN 1392-1215. *Pieņemts publicēšanai*.
9. A.Lorencs, I.Mednieks, M.Pukitis, J.Sinica-Sinavskis, " Fusion of Multisensor Data Based on Different Multidimensional Distributions", Electronics and Electrical Engineering, ISSN 1392-1215. *Iesniegts publicēšanai*.

Literatūra

Publikācijas

Paldies par Jūsu uzmanību!

Vai ir kādi jautājumi?

- ▶ kontakti: Juris Siņica-Siņavskis
- ▶ e-pasts: jss@edi.lv

Ievads

Pamatnostādnes

Literatūras
pārskats

Indian Pines
dataset

GRSS piemērs

Spektra joslu izvēle

klasifikators

Rezultāti

Secinājumi

Literatūra

Publikācijas