

ОБРОБКА ЗОБРАЖЕНЬ ТА РОЗПІЗНАВАННЯ ОБРАЗІВ

УДК 621.391

<https://doi.org/10.15407/vidbir2021.49.045>

АНАЛІЗ КОСМІЧНИХ ЗНІМКІВ МЕТОДАМИ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ ТА МАРКОВАНИХ ВИПАДКОВИХ ТОЧКОВИХ ПОЛІВ

Р. Я. Косаревич, О. В. Альохіна, Б. П. Русин,
О. А. Луцик, Н. А. Піць, Д. В. Івченко

Фізико-механічний інститут ім. Г. В. Карпенка НАН України, Львів

E-mail: kosarevych@ipm.lviv.ua, olutsyk@ipm.lviv.ua, rusyn@ipm.lviv.ua

Запропоновано методологію аналізу зображень дистанційного зондування земної поверхні для виявлення міжвидових залежностей під час біогеоценозу. Методи класифікації на основі згорткових мереж застосовано до набору фрагментів вхідного зображення. Набір центрів фрагментів зображень окремого класу розглянуто як випадкову точкову конфігурацію, властивості якої описують за допомогою характеристик маркованих випадкових точкових полів. Досліджено серію зображень дистанційного зондування, щоб виявити взаємні залежності між точковими конфігураціями різних класів для моніторингу їх розвитку.

Ключові слова: дистанційне зондування, згорткові нейронні мережі, випадкові точкові поля.

ANALYSIS OF REMOTE SENSING IMAGES BY METHODS OF CONVOLUTIONAL NEURAL NETWORKS AND MARKED RANDOM POINT FIELDS

R. Ya. Kosarevych, O. V. Alokhina, B. P. Rusyn,
O. A. Lutsyk, N. A. Pits, D. V. Ivchenko

H. V. Karpenko Physico-Mechanical Institute of the NAS of Ukraine, Lviv

The methodology of remote sensing image analysis for detection of dependences in the process of development of biological species is proposed. Classification methods based on convolutional networks are applied to a set of fragments of the input image. In order to increase the accuracy of classification by increasing the training and test samples, an original method of data augmentation is proposed. For a series of images of one part of the landscape, the fragments of images are classified by their numbers, which coincide with the numbers of the previously classified image of the training and test samples which are created manually. This approach has improved the accuracy of classification compared to known methods of data augmentation. Numerous studies of various convolutional neural networks have shown the similarity of the classification results of the remote sensing images fragments with increasing learning time with the complication of the network structure. A set of image fragment centers of a particular class is considered as random point configuration, the class labels are used as a mark for every point. Marked point field is considered as consisting of several sub-point fields in each of which all points have the same qualitative marks. We perform the analysis of the bivariate point pattern to reveal relationships between points of different types, using the characteristics of marked random point fields. Such relationships can characterize dependences and relative degrees of dominance. A series of remote sensing images are studied to identify the relationships between point configurations that describe different classes to monitor their development.

Keywords: remote sensing, convolutional neural networks, random point fields.

Вступ. За результатами аналізу зображень дистанційного зондування можна розв'язувати широкий спектр прикладних задач. Зокрема, моніторити використання природних ресурсів, прогнозувати метеорологічну ситуацію, контролювати

© Р. Я. Косаревич, О. В. Альохіна, Б. П. Русин, О. А. Луцик, Н. А. Піць, Д. В. Івченко, 2021

переміщення об'єктів та тварин, моніторити ландшафти, виявляти пожежі та інші природні катаклізми, контролювати нерегламентовану забудову тощо.

Для цього часто застосовують як класичні методи оброблення зображень [1, 2], так і ефективніші сучасні, засновані на використанні згорткових нейронних мереж [3–5]. До таких задач відносять сегментацію та класифікацію зображень, оскільки дистанційний моніторинг полягає у виділенні та встановленні кількісних характеристик досліджуваних об'єктів [6], хоча не менш важливо встановити залежності між існуючими елементами екосистеми, виявити та описати їх взаємний вплив. З цією метою пропонуємо застосувати марковані випадкові точкові поля як моделі взаємодії об'єктів екологічних досліджень, які подають точковими конфігураціями. Така модель популярна в біології, матеріалознавстві, сейсмології [7–9]. Виявивши вид взаємодії між об'єктами екологічного дослідження, можна глибше зрозуміти приховані процеси, які їх пов'язують, а також прогнозувати їх розвиток.

У задачах класифікації поєднують класичні і сучасні методи, коли підміняють повнозв'язні шари нейронної мережі класифікаторами. Тобто з допомогою нейронної мережі формують набір ознак, зокрема, до класу відносять методом класифікації [10]. За такого розділення вдається повністю вжити найкращі властивості кожного підходу. Вибір ознак, формування т.зв. їх алфавіту – задача евристична, яка залежить від об'єкта класифікації і придатна для якісних зображень. Згорткові нейронні мережі (ЗНМ) можна адаптувати до різних за формою та якістю зображень об'єкта класифікації для його кількісного опису, а методи класифікації, володіють розвинутішим апаратом для віднесення об'єкта до того чи іншого класу.

Таблиця 1. Набори даних дистанційного зондування

Набір даних	Зображення у класі	Кількість класів	Всього зображень	Роздільна здатність, м/п	Розмір зображення, пікс.
	шт.				
UC Merced Land Use	100	21	2100	0,3	256 × 256
WHU-RS19	~ 50	19	1005	0,5	600 × 600
RSSCN7	400	7	2800	–	400 × 400
RSC11	~ 100	11	1232	0,2	512 × 512
SIRI-WHU	200	12	2400	2	200 × 200
AID	200 ~ 400	30	10000	0,5 ~ 0,8	600 × 600
EuroSAT	2000 2500 3000	10	27000	–	64 × 64
NWPU-RESISC45	700	45	31500	~ 30...0,2	256 × 256
PatternNet	800	38	30400	0,062 ~ ~ 4,693	256 × 256
RSI-CB	RSI-CB128(~800) RSI-CB256(~690)	RSI-CB128(45) RSI-CB256(35)	RSI-CB128(36707) RSI-CB256(24747)	0,3 ~ 3	128 × 128 256 × 256
RSD46-WHU	500...3000	46	117000	0,5 ~ 2	

Основою високої точності класифікації і далі залишається навчальна вибірка для ЗНМ. Для якісного її формування необхідні значні зусилля, особливо під час дистанційного зондування. Такі зображення, в першу чергу, спотворені розмиттям, джерелом якого є атмосфера. Іншим суттєвим чинником є роздільна їх здатність. Якісні зображення із високою роздільною здатністю рідко доступні, тому найчастіше для моніторингу використовують зображення із розрізненням $\sim 10 \text{ м}^2$ в одному пікселі. Це суттєво обмежує класифікацію необхідних об'єктів, які можна подати декількома пікселями, і створює складнощі під час формування навчальних вибірок класів зображень через їх подібність.

Відомо, що якісна класифікація зображень прямо пропорційна об'єму навчальної вибірки. База зображень ImageNet, яка є еталоном для сучасних засобів класифікації, містить більше мільйона класифікованих зображень. Загальновідомі бази зображень дистанційного зондування US Merced[11], WHU-RS19[12], RSSCN7[13] тощо (див. табл. 1) містять, у середньому, сотні зображень кожного класу доволі високої роздільної здатності ($(0,2\dots4) \text{ м}^2$). ЗНМ також дають можливість виконати попереднє навчання на відомих наборах даних, чи відразу використати набори сформованих ними коефіцієнтів, а потім “донавчити” мережу на власних даних. Але досліджувані зображення мають відповідати параметрам зображень відомих наборів, тобто довжині, ширині, кількості каналів та градацій, що не завжди можливо.

Тому сформуванню навчальної вибірки зображень для класифікації за допомогою ЗНМ і подальшого аналізу – актуальне завдання. Для його спрощення пропонуємо шаблонно доповнити початковими навчальними вибірками класів зображень на основі попередньої класифікації досліджуваної сцени.

Формування набору даних. Для досліджень формування навчальної вибірки використовували зображення Шацького національного природного парку (ШНПП), отримані зі супутника Landsat8 у видимому спектральному діапазоні. Набір даних формували упродовж 2017–2020 рр. Відбирали зображення, отримані за червень–вересень, що повністю відтворюють розвинену рослинність місцевості.

На зображеннях подано ділянку ШНПП площею 450 км^2 . Розмір вихідного зображення 3420×4380 пікселів, роздільна здатність $\sim 10 \text{ м}^2/1$ пікс. За одним зображенням сформували навчальну, тестову та валідаційну вибірки фрагментів зображення розміром 10×10 пікселів. Розміри цих вибірок становили 11792; 1664 і 482 фрагменти, відповідно. Щоб розширити вибірки, їх доповнювали їх відповідними фрагментами низки зображень. Це стало можливим, оскільки одержаний набір даних відтворював одну і ту ж ділянку Земної поверхні. Тому, поставивши у відповідність кожному фрагменту початкової навчальної вибірки мітку класу та виконавши навчання ЗНМ, за класифікацією фрагментів ряду зображень доповнили ними початкові вибірки. В результаті розміри цих вибірок зросли до 47213; 10443 та 2182 фрагментів, відповідно. Загалом утворили навчальну 186027; тестову 45019 та валідаційну 22349 вибірки фрагментів зображень.

Аналіз точності класифікації зображень дистанційного зондування. Слід зауважити, що традиційно збільшити навчальну та інші вибірки зображень можна їх аугментацією [14]. Базові методи використовують поворот, зсув, масштабування, зміна кольорової палітри та їх комбінації. Загалом аугментацією можна підвищити точність класифікації на 5...10%. Треба, однак, відмітити, що, як правило, точність класифікації збільшують аугментацію для зображень вихідної вибірки, які різняться між собою. Для фрагментів зображення дистанційного зондування така властивість трапляється нечасто, тому аугментація у цьому випадку призводить до копіювання фрагментів вихідної вибірки і практично не впливає на точність класифікації (див. табл. 2).

Таблиця 2. Порівняння точності класифікації зі застосуванням аугментації

Розмір тестової вибірки	Точність класифікації без аугментації	Точність класифікації із аугментацією	Час навчання без аугментації	Час навчання з аугментацією
	%		с	
1664	80	83	30	105

Для класифікації фрагментів зображень дистанційного зондування використовували відомі конфігурації ЗНМ. Серед них як потужні EffNet [15], так і найпростіші LeNet [16]. Несподіваною виявилась подібність результатів класифікації різними ЗНМ. Зокрема, для згаданих вище ЗНМ відповідні результати різняться не більш ніж на 2%. Це можна пояснити видом зображень, на яких через спосіб формування переважають крупні деталі і додаткові шари складніших нейромережових структур залишаються не задіяними сповна.

Таблиця 3. Порівняння точності класифікації зі застосуванням різних ЗНМ

Набір даних	Точність класифікації (top-1)		Точність класифікації (top-5)	
	%			
	EffNet	LeNet	EffNet	LeNet
11792 / 1664 / 482	96 / 80 / 68	80 / 76 / 65	100 / 98 / 79	100 / 99 / 75
47213 / 10443 / 2182	96 / 86 / 77	86 / 88 / 67	100 / 99 / 90	99 / 99 / 89
186027 / 45019 / 22349	97 / 90 / 89,7	87 / 89 / 88,9	100 / 99 / 95	99 / 99 / 93

Формування та аналіз випадкових точкових конфігурацій. Розбиваючи вхідне зображення на фрагменти та класифікуючи їх, можна сформувати низку точкових конфігурацій, кожна з яких відповідає окремому класу фрагментів. Якщо за точку виберемо центр фрагмента, тоді утворена конфігурація відповідатиме розташуванню фрагментів одного класу (рис. 1).

У багатьох галузях техніки і економіки часто необхідно статистично описати послідовність подій в окремих точках простору або в окремі моменти часу. Послідовність подій найчастіше характеризують моментами їх появи на часовій осі і називають потоком випадкових подій [17], або випадковим точковим процесом, оскільки реалізацією такого процесу є випадкова послідовність точок, хоча головну увагу приділяють моменту виникнення події. Для двовимірного випадкового процесу більше значення вже має місце виникнення події проти інших подій впродовж невеликого проміжку часу. Тоді випадкові точкові процеси називають випадковими точковими полями (ВТП), за якими можна встановити закономірності розташування випадкових подій, а отже, виявити їх взаємний вплив та вид. Встановивши властивості процесу, яким описують об'єкт досліджень, отримаємо більше відомостей і про сам об'єкт. Історично можливості аналізу різних об'єктів за допомогою ВТП почали застосовувати у галузях, де розташування подій-об'єктів можна позначити на карті: лісництво, сейсмологія, біологія, економіка, астрономія, соціологія [7–9]. Проте останнім часом такі методи все частіше застосовують для аналізу зображень, коли моделлю їх формування є випадковий процес [18].

Одна із основних властивостей ВТП – характер розташування елементів в області простору: кластерне, регулярне чи випадкове і, відповідно, вид взаємодії між ними. Для кластерного припускають існування зв'язку, за якого вони виникають на як завгодно малій відстані, для регулярного – їх поява обмежена певною відстанню між подіями, а для випадкових – відсутній чіткий зв'язок між появою подій.

Однорідний точковий процес Пуассона є фундаментальною моделлю для ВТП, а також основою для побудови складніших моделей. Цей процес формалізує поняття “абсолютної” випадковості, яка проявляється у відсутності визначеної структури утвореної конфігурації точок. Для перевірки гіпотези про повну просторову випадковість ВТП, тобто його тотожність процесу Пуассона, розробили низку тестів, зокрема тест Кларка–Еванса [19], який базується на перевірці відповідності нормального розподілу стандартизованого середнього значення відстані до найближчого сусіда для елементів ВТП. Інший спосіб аналізу ВТП – обчислення його характеристик другого порядку, серед яких K -, g -, J - функції тощо [17].

Інші можливості відкриваються за одночасного аналізу взаємного розташування двох і більше точкових конфігурацій. Так можна встановити, наприклад, міжвидові залежності для оцінки біологічних об'єктів. Для цього і використовують зображення дистанційного зондування. Традиційно точкові конфігурації утворюють, наносючи на карту події, що відбулися. Це трудомісткий процес, оскільки необхідно володіти точними відстанями між об'єктами дослідження, які здебільшого розташовані на значних за площею ділянках.

Для одночасного аналізу декількох точкових конфігурацій оцінюють властивості маркованих точкових процесів, які відрізняються від звичайних додатковим параметром – маркером, який описує певну характеристику як категоріальну або кількісну, наприклад, діаметр дерева чи вид. Для цього використовують аналоги двовимірних характеристик звичайних точкових процесів – K -, g -, J - функції тощо [17]. Для прикладу наведемо два вирази цих функцій. Для K -функції за єдиної точкової конфігурації

$$\lambda K(r) = E_o(N(b(o, r) \setminus \{o\})),$$

де λ – кількість точок на одиницю площі, а $K(r)$ – середня їх кількість у крузі радіусом r , центр якого розташований у типовій точці, яку не враховують.

Аналогічно K -функція для декількох точкових конфігурацій має вигляд

$$\lambda_i K_{ij}(r) = E_{oi}(N_j(b(o, r) \setminus \{o\})),$$

де λ_i – кількість точок типу i на одиницю площі, а $K_{ij}(r)$ – середня кількість точок типу j у крузі радіуса r , центр якого розташований у точці i .

Для статистичних досліджень, пов'язаних із моніторингом розвитку певного регіону, потрібні значні витрати часу та ресурсів. На початковому етапі необхідно оцінити обсяги наявних складових, їх економічно важливі характеристики, а далі вивчити їх якість. Сьогодні сучасні технології, зокрема дистанційне зондування та цифрові космічні знімки, використовують для збирання та аналізу необхідної інформації, розроблення різноманітних кадастрів, попередження зникнення окремих видів рослин, тощо. Тому для дистанційного зондування земної поверхні екологія ландшафту та пов'язані з нею статистичні методи стають все важливіші [20] (рис. 1 і 2).

На рис. 2 побудовано залежності між складовими ВТП з урахуванням взаємної присутності елементів однієї з них в околі типової точки іншої за допомогою т.зв. функції зв'язку маркерів – сумісної ймовірності взаємної присутності маркерів різних типів $p[i, j](r)$, яка залежить від відстані між ними. Якщо маркери точок незалежні та однаково розподілені, то $p[i, j](r) = p[i]p[j]$, де $p[i]$ – ймовірність

того, що точка має тип i . Якщо $p[i, j](r) > p[i]p[j]$, то це вказує на позитивний зв'язок між двома типами, тоді як менші значення – на негативний. Наприклад, кількість елементів одного біологічного виду в околі іншого може бути індикатором сумісності останніх. Побудовано залежності між точковими конфігураціями для пар класів, які виділенні на зображенні дистанційного зондування досліджуваного регіону. Вони можуть вказати, наприклад, на тенденції розвитку рослинності регіону, розширення чи звуження областей поширення окремих видів.




Рис. 1. Зображення дистанційного зондування (а) та відповідне точкове поле (б).

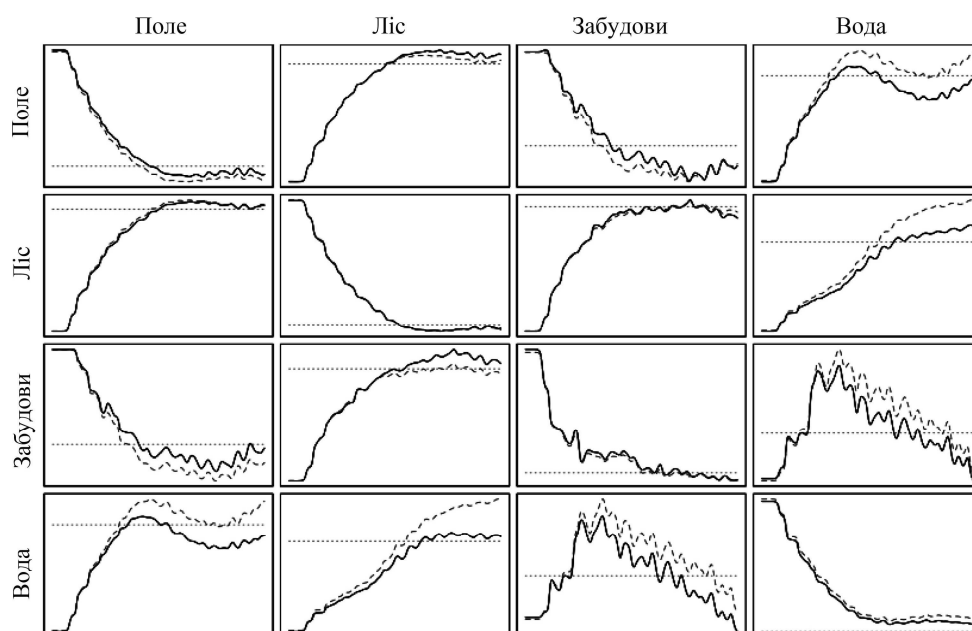


Рис. 2. Залежності між різними складовими випадкового точкового поля.

ВИСНОВКИ

Для моніторингу довкілля слід вдосконалити існуючі та розвинути нові підходи до аналізу результатів дистанційного зондування. Найпоширенішим джерелом

такої інформації є космічні знімки Земної поверхні. Запропоновано методологію аналізу зображень дистанційного зондування, яка поєднує підходи класифікації зображень за допомогою ЗНМ та залежності між складовими маркованих випадкових точкових полів, сформованих на основі цих зображень. Запропоновано новий підхід для збільшення навчальних, тестових та валідаційних вибірок для підвищення точності класифікації зображень дистанційного зондування за допомогою ЗНМ.

1. Gómez-Chova, L.; Tuia, D.; Moser, G.; Camps-Valls, G. Multimodal Classification of Remote Sensing Images: a Review and Future Directions, *Proceedings of the IEEE*, **2015**, 103(9), 1560–1584. <https://doi.org/10.1109/JPROC.2015.2449668>
2. Li, M.; Zang, S.; Zhang, B.; Li, S.; Wu, C. A review of remote sensing image classification techniques: The role of spatio-contextual information, *European Journal of Remote Sensing*, **2014**, 47(1), 389–411. <https://doi.org/10.5721/EuJRS20144723>
3. Alajlan, N.; Bazi, Y.; Melgani, F.; Yager, R. R. Fusion of supervised and unsupervised learning for improved classification of hyperspectral images, *Information Sciences*, **2012**, 217, 39–55. <https://doi.org/10.1016/j.ins.2012.06.031>
4. Liu, S.; Luo, H.; Tu, Y.; He, Z.; Li, J. Wide contextual residual network with active learning for remote sensing image classification, *In GARSS 2018-2018 IEEE Int. Geoscience and Remote Sensing Symposium*, **2018**, July, 7145–7148. <https://doi.org/10.1109/IGARSS.2018.8517855>
5. Lee, H.; Kwon, H. Going deeper with contextual CNN for hyperspectral image classification, *IEEE Transact. on Image Proc.*, **2017**, 26(10), 4843–4855. <https://doi.org/10.1109/TIP.2017.2725580>
6. Pashkov, D. P. Analysis of the possibilities of using space systems for remote sensing of the Earth to solve environmental problems, *Air Force Science and Technology of the Armed Forces of Ukraine*, **2014**, 2(15), 184–188. [in Ukrainian]
7. Vasudevan, K.; Eckel, S.; Fleischer, F.; Schmidt, V.; Cook, F. A. Statistical analysis of spatial point patterns on deep seismic reflection data: a preliminary test, *Geophysical J. International*, **2007**, 171(2), 823–840. <https://doi.org/10.1111/j.1365-246X.2007.03572.x>
8. Haase, P. Spatial pattern analysis in ecology based on Ripley's K function: Introduction and methods of edge correction, *J. of Vegetation Science*, **1995**, 6(4), 575–582. <https://doi.org/10.2307/3236356>
9. Cheng, Y. F.; Luo, J. L. Statistical analysis of metastable pitting events on carbon steel, *British Corrosion Journal*, **2000**, 35(2), 125–130. <https://doi.org/10.1179/000705900101501146>
10. Jiang, S.; Zhao, H.; Wu, W.; Tan, Q. A novel framework for remote sensing image scene classification, *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, **2018**, 42(3). <https://doi.org/10.5194/isprs-archives-XLII-3-657-2018>
11. Yang, Y.; Newsam, S. Bag-of-visual-words and spatial extensions for land-use classification, *Proc. of the 18th SIGSPATIAL Int. Conf. on Adv. in Geographic Information Systems*, **2010**, November, 270–279. <https://doi.org/10.1145/1869790.1869829>
12. Xia, G. S.; Yang, W.; Delon, J.; Gousseau, Y.; Sun, H.; Maître, H. Structural high-resolution satellite image indexing, *In ISPRS TC VII Symposium-100 Years ISPRS*, **2010**, July, 38, 298–303.
13. Zou, Q.; Ni, L.; Zhang, T.; Wang, Q. Deep learning based feature selection for remote sensing scene classification, *IEEE Geoscience and Remote Sensing Letters*, **2015**, 12(11), 2321–2325. <https://doi.org/10.1109/LGRS.2015.2475299>
14. Cubuk, E. D.; Zoph, B.; Mane, D.; Vasudevan, V.; Le, Q. V. Autoaugment: Learning augmentation policies from data, *arXiv Preprint*, **2018**, arXiv:1805.09501. <https://doi.org/10.1109/CVPR.2019.00020>
15. Freeman, I.; Roese-Koerner, L.; Kummert, A. Effnet: An efficient structure for convolutional neural networks, *25th IEEE Int. Conf. on Image Proc.*, **2018**, 6–10. <https://doi.org/10.1109/ICIP.2018.8451339>
16. LeCun, Y.; Boser, B.; Denker, J. S.; Henderson, D.; Howard, R. E.; Hubbard, W.; Jackel, L. D. Backpropagation applied to handwritten zip code recognition, *Neural Computation*, **1989**, 1(4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
17. Baddeley, A. Spatial Point Process Modelling and Its Applications, *Stochastic Geometry*, **2007**, 1–75. <https://doi.org/10.1007/3-540-38174-0>
18. Kosarevych, R. Ya. An approach to estimating the grain size of a material using point pattern. Computational methods and systems of information transformation, *Materials of the II Scientific and Technical Conference*, September 20–21, **2012**: Lviv, 2012, 110–113. [in Ukrainian]
19. Clark, P. J.; Evans, F. C. Distance to nearest neighbor as a measure of spatial relationships in populations, *Ecology*, **1954**, 35(4), 445–453. <https://doi.org/10.2307/1931034>
20. Stoyan, D.; Penttinen, A. Recent applications of point process methods in forestry statistics, *Statistical Science*, **2000**, 61–78. <https://doi.org/10.1214/ss/1009212674>

Одержано 19.07.2021