

Indexy pro hodnocení prostorové autokorelace plošných jevů

Moranův (I) a Gearyho (C) index jako míry prostorové autokorelace plošných jevů

- Jsou využitelné pro intervalová a poměrová data
- Vhodnější vlastnosti vzhledem k rozdělení hodnot má index I.
- Jsou založeny na porovnávání hodnot atributů sousedních ploch.
- Mají-li tyto sousední plochy v celé studované oblasti podobné hodnoty, potom obě statistiky budou svědčit o silné pozitivní prostorové autokorelaci a naopak.
- Obě statistiky využívají odlišný přístup k porovnávání hodnot sousedních ploch.

Moranův (I) index

$$I = \frac{n \sum \sum w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{W \sum (x_i - \bar{x})^2}$$

kde x_i je hodnota proměnné v ploše i
 w_{ij} jsou váhy, W matice vah

Hodnota indexu kolísá od -1 pro negativní prostorovou autokorelaci do +1 pro pozitivní prostorovou autokorelaci.

Očekávaná hodnota (případ nulové prostorové autokorelace)

$$E_I = -\frac{1}{(n-1)}$$

Váhy - matice binární či stochastická.

Interpretace Moranova I

- Budou-li ve zpracovávané oblasti převažovat sousedé s obdobnými hodnotami, Moranův index I bude kladný.
 - Vypočteme hodnoty I a E(I) a následně musíme zjistit, zda rozdíl mezi nimi je statisticky významný.
 - Tento rozdíl je opět nutné vztáhnout k míře variability (např. rozptylu) a pomocí ní odvodit standardizovanou hodnotu z-skóre
- $$Z_n = \frac{I - E(I)}{\sigma^2(I)}$$
- Odhady rozptylu se budou lišit podle způsobu, jakým mohou být hodnoty vyšetrovaného atributu přiřazeny k jednotlivým plochám – viz. předpoklad **normality** a předpoklad **náhodnosti**
 - Pokud je hodnota $Z_n(I)$ menší (resp. větší) než -1,96 (resp. 1,96) je hodnota indexu I statisticky významně negativní (resp. pozitivní) na hladině významnosti $\alpha=0,05$.

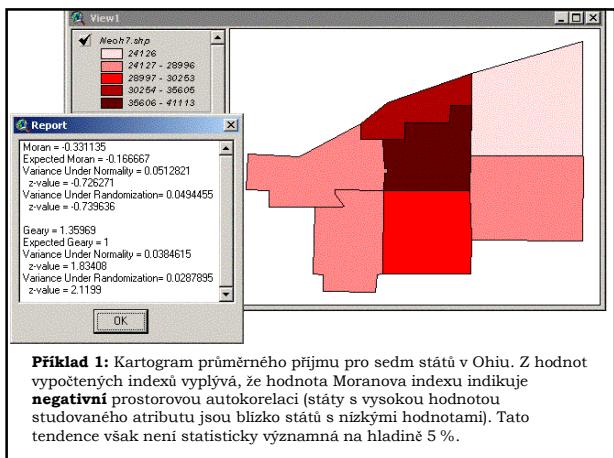
Gearyho poměr C

$$C = \frac{(n-1) \sum \sum w_{ij} (x_i - x_j)^2}{2W \sum (x_i - \bar{x})^2}$$

- Jako vah se nejčastěji využívá matice binární či stochastické.
- Ve srovnání se vzorcem pro výpočet Moranova indexu Gearyho index porovnává hodnoty atributů přímo mezi sebou.
- Pro hodnotu indexu není rozhodující, která z hodnot x_i a x_j je větší či menší, ale jaký je jejich absolutní rozdíl – jejich nepodobnost (ve výrazu je druhá mocnina jejich rozdílu).
- Gearyho index nabývá hodnot v intervalu 0 až 2.
- Hodnota nula indikuje dokonalou pozitivní autokorelaci (všechny sousední hodnoty atributů jsou stejně). Naopak hodnota 2 indikuje dokonalou negativní prostorovou autokorelaci. Hodnota 1 znamená nulovou prostorovou autokorelaci – náhodné uspořádání
- Očekávaná hodnota Gearyho indexu nezávisí na počtu posuzovaných ploch n, ale má vždy hodnotu 1.

Interpretace Gearyho poměru C

- Vypočtené hodnoty indexu C lze porovnat s hodnotou jedna (očekávanou)
- Pro prokázání statisticky významného rozdílu je nutné vypočítat hodnotu rozptylu a z-skóre.
- Hodnota rozptylu se opět vypočte rozdílně v závislosti na předpokladu normality či náhodnosti.
- Z výše uvedeného plyne, že negativní hodnota z-skóre znamená pozitivní prostorovou autokorelaci a kladná hodnota z-skóre znamená negativní.

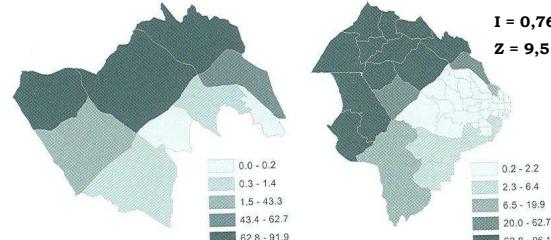


Omezení globálních měr I, C

Pouze řeší, zda:

Podobné blízko sebe – pozitivní prostorová autokorelace

Nepodobné blízko sebe – negativní prostorová autokorelace



- rozsah studované oblasti
- počet objektů (ploch)

Obecná G - statistika

- Indexy I a C mají dobře definované statistické vlastnosti, které popisují prostorovou autokorelaci globálně
- Nejsou však efektivní k identifikaci rozdílných shluků prostorového uspořádání uvnitř oblasti.
- Identifikují oblasti s podobnými hodnotami atributů, nerozlišují však, zda tyto podobné hodnoty nabývají vysokých či nízkých hodnot.
- Shluky ploch (též, místa prostorové koncentrace - **spatial concentration**) vysokých hodnot vyšetřovaného atributu ve studované oblasti se označují jako „**hot spots**“, naopak místa se shluky nízkých hodnot jako „**cold spots**“.
- Odlišit oby typy shluků lze pomocí tzv. **obecné G-statistiky (general G-statistics)**.

Obecná G - statistika

$$G(d) = \frac{\sum \sum w_{ij}(d)x_i x_j}{\sum \sum x_i x_j} \quad \text{pro } i \neq j$$

- G-statistika je definována vzdálostí d mezi plochou i a plochami sousedními.
- Váha $w_{ij}(d)$ má hodnotu 1, jestliže se plocha j nachází ve vzdálenosti menší či rovné d od plochy i , jinak je váha rovna 0.
- Matice vah je maticí binární a symetrickou, vztahy sousedství jsou definovány vzdáleností d . Suma těchto vah matice se rovná:

$$W = \sum \sum w_{ij}(d) \quad \text{pro } i \neq j$$

Interpretace G - statistiky

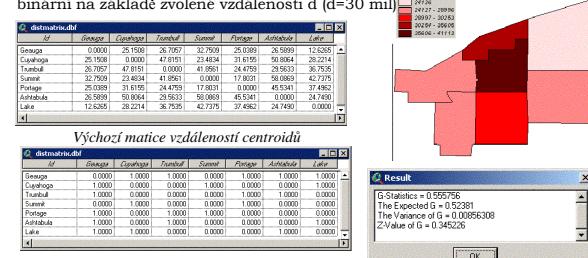
- Vysoké hodnoty $G(d)$ indikují prostorovou asociaci vysokých hodnot (**hot spots**) známého atributu, nízké $G(d)$ potom prostorovou asociaci nízkých hodnot (**cold spots**).
- Před výpočtem $G(d)$ je nutné určit vzdálosť d , která definuje plochy, které budou považovány za sousedy plochy posuzované. Musí být vzhodně zvolena tak, aby posuzovaná plocha měla alespoň jednoho souseda.
- K interpretaci $G(d)$ je nutné vypočítat očekávanou hodnotu $G(d)$, tedy $E(G)$ a následně standardizovanou hodnotu z-skóre a tedy i rozptylu hodnoty $G(d)$. Očekávaná hodnota $G(d)$ bude:

$$E(G) = \frac{W}{n(n-1)}$$

- Očekávaná hodnota odpovídá nulové prostorové asociaci. Např. je-li vypočtená hodnota $G(d)$ větší než očekávaná, můžeme říci, že pozorované uspořádání vykazuje pozitivní prostorovou asociaci.

- Statistickou významnost tohoto tvrzení je opět nutné testovat výpočtem hodnoty rozptylu a Z-skóre. Hodnota z-skóre menší než 1,96 indikuje statisticky nevýznamný výsledek na hladině $\alpha=0,05$.

Příklad 2: Jsou použita stejná vstupní data jako v případě I a indexů. Výchozí matici vzdálenosti centroidů je převedena na matici binární na základě zvolené vzdálenosti d ($d=30$ mil)



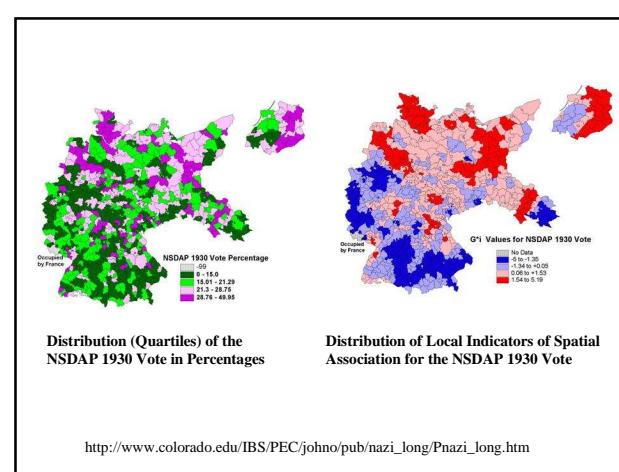
Matice sousedství vypočtená pro $d=30$

Vypočtená hodnota $G(d)$ vykazuje mírnou úroveň prostorové asociace, podle hodnoty z-skóre však výsledek není statisticky významný. Jinými slovy – dané uspořádání průměrného příjmu v sedmi státech Ohia je spíše výsledkem náhody než určitého systematického procesu.

Lokální statistiky prostorové autokorelace

- Výše uvedené indexy jsou příkladem indexů **globálních**.
- Hodnoty prostorové autokorelace se mohou v různých sub- oblastech měnit. Navíc můžeme očekávat, že pozitivní autokorelace lze nalézt v jednom sub-regionu a negativní v jiném.
- LISA (Local Indicators of Spatial Association)** - lokální verze Moranova a Gearyho indexu.
- Ke zjištění úrovně prostorové autokorelace na lokální úrovni se vypočte hodnota indexu pro každou plochu zpracovávaného území.

	-0.133514	1.191483
-0.114093	-0.517704	-0.581443
-0.199405	0.480950	0.071014
	0.122081	0.343143



Lokální Moranův index pro jednotku i :

$$I_i = z_i \sum_j w_{ij} z_j$$

kde z_i a z_j jsou odchylky od průměru nebo

$$z_i = \frac{(x_i - \bar{x})}{\sigma}$$

kde σ je směrodatná odchylka x_i .

- Vysoké hodnoty znamenají kumulaci podobných hodnot atributů (vysokých či nízkých) v sousedních plochách, nízké hodnoty potom kumulaci odlišných hodnot atributů.
- Hodnoty w_{ij} mohou představovat po řadách standardizovanou matici vah, lze použít i jiných matic vah.

Lokální verze Gearyho poměru:

$$c_i = \sum_j w_{ij} (z_i - z_j)^2$$

Shlukování podobných hodnot atributů vede k nízkým hodnotám tohoto indexu a naopak.

Lokální G-statistika

$$G_i(d) = \frac{\sum_j w_{ij}(d)x_j}{\sum_j x_j} \quad \text{pro } i \neq j$$

I v případě lokálních měr je nutné interpretovat hodnoty indexů pomocí očekávaných hodnot, hodnot rozptylu a standardizovaných skóre

Příklad 3: Pro data z příkladu 1 byly vypočteny hodnoty lokálního Moranova indexu I (pro každý stát). Jako matici vah byla použita matica stochastická. Výsledky jsou prezentovány ve formě kartogramu.

Stát	Id	Bikergy	Cyberlogix	Forrester	Summit	Platinum	Akademie	České
Oregon	1	0.0000	0.1667	0.1667	0.1667	0.1667	0.1667	0.1667
Washington	2	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
California	3	0.3333	0.0000	0.0000	0.0000	0.3333	0.3333	0.0000
Florida	4	0.3333	0.3333	0.0000	0.0000	0.3333	0.3333	0.0000
Texas	5	0.3333	0.3333	0.3333	0.0000	0.3333	0.3333	0.0000
Illinois	6	0.3333	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000
Michigan	7	0.3333	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000
North Carolina	8	0.3333	0.0000	0.3333	0.0000	0.0000	0.0000	0.3333
Georgia	9	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000	0.0000
Alabama	10	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Louisiana	11	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Arkansas	12	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Mississippi	13	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Missouri	14	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Tennessee	15	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Wyoming	16	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Montana	17	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
North Dakota	18	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
South Dakota	19	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Idaho	20	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Virginia	21	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	22	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	23	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	24	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	25	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	26	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	27	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	28	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	29	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	30	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	31	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	32	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	33	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	34	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	35	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	36	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	37	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	38	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	39	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	40	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	41	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	42	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	43	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	44	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	45	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	46	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	47	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	48	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	49	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	50	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	51	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	52	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	53	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	54	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	55	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	56	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	57	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	58	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	59	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	60	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	61	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	62	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	63	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	64	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	65	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	66	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	67	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	68	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	69	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	70	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	71	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	72	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	73	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	74	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	75	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	76	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	77	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	78	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	79	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	80	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	81	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	82	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	83	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	84	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	85	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	86	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	87	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	88	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	89	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	90	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	91	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	92	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	93	0.3333	0.3333	0.3333	0.0000	0.0000	0.0000	0.0000
Pennsylvania	94	0.3333						

Moranovo korelační pole (Moran Scatterplot)

Lokální statistiky vystihují prostorovou heterogenitu v jednotlivých částech studovaného území.

Lze jimi identifikovat oblasti s neobvyklými hodnotami měr prostorové autokorelace, které lze označit jako oblasti s **odlehlymi hodnotami (outliers)**.

Efektivním nástrojem pro takovouto diagnostiku území je Moranovo korelační pole založené na regresním počtu.

Předpokládejme, že x značí vektor hodnot x_i vyjádřený v odchylkách od průměru ($x_i - \bar{x}$)

Dále W značí po řádcích standardizovanou matici vah.

Lze sestavit **regresní závislost hodnot Wx na x** . Směrnice této regresní závislosti indikuje vzájemný vztah sousedních hodnot atributů.

Moranovo korelační pole (Moran Scatterplot)

Sestavíme regresní závislost hodnot Wx na x . Směrnice této regresní závislosti indikuje vzájemný vztah sousedních hodnot atributů.

$$x = a + IWx$$

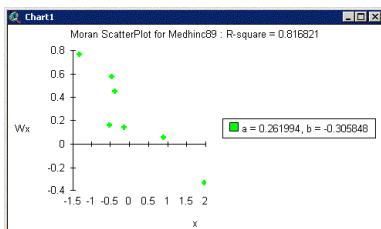
kde parametr a značí vektor koeficientů (intercept).

- Hodnota I je regresní koeficient reprezentující směrnici a také hodnotou Moranova globálního indexu I .

Vynesení regresní závislosti Wx na x umožňuje identifikovat odlehle hodnoty. Pokud budou mít všechna pozorování podobné hodnoty prostorové autokorelace, v korelačním poli budou body tvorit regresní přímku.

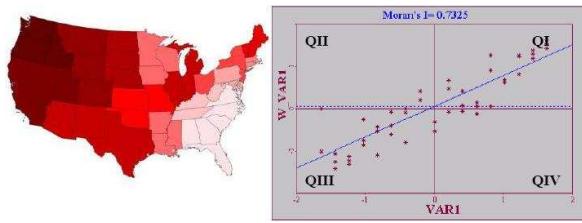
Pokud některá pozorování budou ukazovat lokálně výrazně vysoké či nízké hodnoty prostorové autokorelace ve vztahu k jejich sousedům, tato pozorování budou v grafu tvorit body výrazně nad či pod regresní čarou.

Příklad 4: Hodnota Moranova indexu (viz. Příklad 1) indikuje slabou negativní prostorovou autokoreaci (státy s vysokou hodnotou studovaného atributu jsou blízko států s nízkými hodnotami).



Parametry b představují hodnotu Moranova indexu I . Z grafu je patrné že príjem (x) je nepravo úměrný význam hodnotě příjmu (Wx).

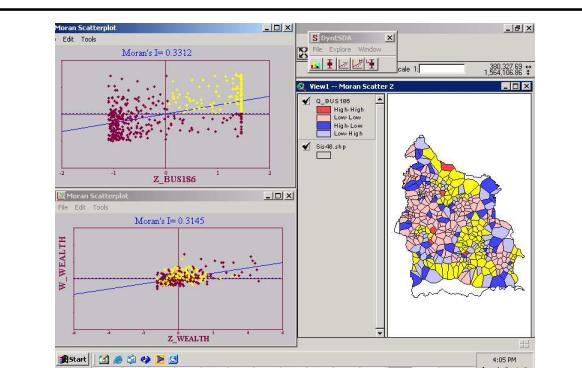
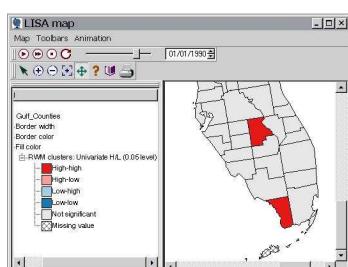
Množinou bodů lze proložit přímku. Body, které se výrazně odchylují od přímky představují „outliers“ – představují oblasti s výrazně odlišnými hodnotami prostorové autokorelace.



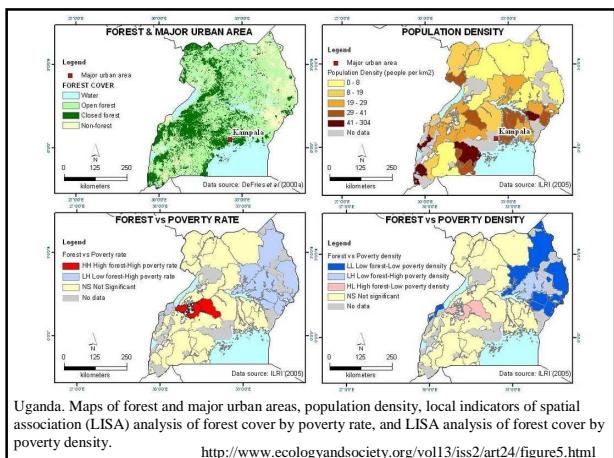
Příklad prostorového uspořádání atributu, který vykazuje silnou pozitivní autokoreaci a příslušný Moranův diagram

Moranovo korelační pole - Interpretace

category	scatter plot quadrant	autocorrelation	interpretation
high-high	upper right	positive	Cluster - "I'm high and my neighbors are high."
high-low	lower right	negative	Outlier - "I'm a high outlier among low neighbors."
low-low	lower left	positive	Cluster - "I'm low and my neighbors are low."
low-high	upper left	negative	Outlier - "I'm a low outlier among high neighbors."



Z Moranova diagramu lze vybrat plochy vykazující stejnou tendenci v hodnotách měr prostorové autokorelace – příklad **pozitivní** prostorové autokorelace



Uganda. Maps of forest and major urban areas, population density, local indicators of spatial association (LISA) analysis of forest cover by poverty rate, and LISA analysis of forest cover by poverty density.

<http://www.ecologyandsociety.org/vol13/iss2/art24/figure5.html>