

## **Variações espaciais e temporais na vegetação; métodos analíticos**

Valério De Patta Pillar  
Departamento de Botânica, UFRGS

A análise de vegetação é comparativa e envolve a consideração de muitas variáveis. Este texto aborda sinteticamente métodos de análise multivariada aplicados a dados de vegetação. Medidas de semelhança, efeito de transformações de dados e a busca de padrões através de classificação e ordenação são discutidos.

### *Introdução*

O estudo da vegetação é fundamentalmente comparativo. Através da análise dos dados de um conjunto de inventários de comunidades vegetais busca-se revelar padrões de variação da vegetação e suas inter-relações, ou seja: (1) tipos de comunidades na paisagem (espaço real), o que envolve classificação e mapeamento da vegetação; (2) padrões de distribuição e associação em espaço abstrato, cujas dimensões são definidas pelas variáveis que descrevem a vegetação, através de técnicas de ordenação e classificação; e (3) relações espaço-temporais, ou seja, as relações entre vegetação e ambiente, entre vegetação e tempo (sucessão), e entre vegetação e fenômenos histórico-geográficos em grande escala, sendo este último objeto da fitogeografia.

Os padrões revelados pela análise são intrinsecamente dependentes do modo como comunidades são delimitadas, descritas e analisadas. O inventário é a descrição de uma comunidade vegetal, arbitrariamente delimitada, e das condições de ambiente nela prevaescentes. Consta de uma lista das populações componentes, geralmente associadas a estimativas de quantidade (frequência, cobertura, densidade, ou biomassa de cada população). Tradicionalmente a taxonomia de organismos reconhece espécies, mas comunidades podem também ser descritas pela sua composição de formas-vitais (Raunkiaer 1907) ou pela sua composição de CSTs (populações de organismos que são idênticos para os caracteres considerados, Orlóci & Orlóci 1985, Pillar & Orlóci 1993). Da mesma forma, vários métodos de análise podem ser usados. Na presença de tantas alternativas, quais caminhos a seguir então? Sugere-se que a solução mais adequada é abordar a descrição e análise da vegetação como um processo de sucessivas aproximações (Poore 1962, Wildi & Orlóci 1987), em que procedimentos são ajustados de forma a que os resultados maximizem a satisfação de um objetivo, e.g., se o estudo busca decifrar inter-relações entre vegetação e ambiente, a escala, a taxonomia e a análise ótimas serão aquelas que produzirem um explicação mais clara dessas inter-relações.

A análise dos dados implica em desemaranhar complexidades, nem sempre evidentes a olho nu, e raramente passíveis de serem tratadas pelos métodos da estatística convencional (Orlóci 1991). Os dados são complexos porque as variáveis envolvidas são numerosas e estão correlacionadas. A vegetação natural é normalmente composta por muitas espécies, as quais

apresentam um grau variado de associação entre si. Também, o meio físico é complexo e pode ser descrito por muitas variáveis. Por isso, o tratamento de dados de comunidades exige o uso de técnicas de análise multivariada. Padrões de distribuição e associação no espaço abstrato são detectados através das análises multivariadas de classificação (análise de agrupamentos, "cluster analysis") e ordenação. O tema é abordado em detalhes em Whittaker (1973), Orlóci (1978), Pielou (1984), Orlóci & Kenkel (1985), Digby & Kempton (1987), Wildi & Orlóci (1990), Feoli & Orlóci (1991) e Podani (1994).

### *Medidas de semelhança*

A base dos métodos de análise multivariada são medidas de semelhança. Estas avaliam objetivamente a similaridade ou dissimilaridade de um par de objetos e são necessárias nas análises de ordenação e classificação. Quando os objetos são inventários a semelhança será maior quanto maior for o número de componentes comuns e quanto mais próximas forem as quantidades com que estes estão presentes. Inventários também podem ser comparados pelas variáveis de ambiente. Quando os objetos são as populações componentes a semelhança (ou grau de associação) será maior quanto maior o número de inventários em que os dois componentes ocorrem juntos e quanto mais próximas são as quantidades com que estes ocorrem.

Há numerosos índices de semelhança propostos. O mais antigo deles, o *índice de similaridade de Jaccard* (1901) é definido por:

$$J_{\alpha\beta} = \frac{a}{a+b+c}$$

Na equação, "a" é o número de populações componentes comuns aos dois inventários  $\alpha$  e  $\beta$ , "b" é o número de populações que ocorrem somente no inventário  $\alpha$ , e "c" é o número de populações que ocorrem somente no inventário  $\beta$ . O índice de Jaccard é qualitativo; não considera as quantidades em que as populações componentes estão presentes. Quando os objetos comparados são as populações componentes  $\alpha$  e  $\beta$ , "a" é o número de inventários em que os componentes  $\alpha$  e  $\beta$  ocorrem juntos, "b" é o número de inventários em que  $\alpha$  está presente e  $\beta$  ausente, e "c" é o número de inventários em que  $\alpha$  está ausente e  $\beta$  presente.

Algumas medidas de semelhança podem ser definidas dentro de um espaço abstrato de comparação, em que as dimensões são as populações componentes das comunidades e a posição dos inventários é definida pelas quantidades de cada uma das populações (Figura 1).

Com base no espaço de comparação define-se uma série de medidas de dissimilaridade (métricas de Minkowski) com a seguinte equação geral:

$$d_{\alpha\beta}^{(k)} = \{\sum |X_{i\alpha} - X_{i\beta}|^k\}^{1/k} \text{ para } i = 1, \dots, p \text{ dimensões}$$

Na equação, k é arbitrário. A equação define a *função valor absoluto* quando k=1, e a *distância euclidiana* quando k=2. Se  $\alpha$  e  $\beta$  são idênticos,  $d_{\alpha\beta}^{(k)} = 0$ .




Figura 1. Se inventários são descritos por apenas 2 populações componentes ( $X_1$  e  $X_2$ ), o espaço de comparação entre os inventários (7 pontos) é definido por duas dimensões. A dissimilaridade entre os inventários  $\alpha$  e  $\beta$  pode ser indicada pela distância euclidiana entre  $\alpha$  e  $\beta$ , que é a hipotenusa do triângulo retângulo formado ( $d_{\alpha\beta} = [(X_{1\alpha} - X_{1\beta})^2 + (X_{2\alpha} - X_{2\beta})^2]^{1/2}$ ). Havendo mais populações componentes, estas constituem dimensões adicionais no espaço e termos adicionais na equação, definindo assim um hiperespaço. Da mesma forma, a similaridade entre os inventários  $\alpha$  e  $\beta$  pode ser medida pelo produto das quantidades com que cada população está presente ( $q_{\alpha\beta} = X_{1\alpha}X_{1\beta} + X_{2\alpha}X_{2\beta}$ ), e novos termos seriam agregados à equação se tivéssemos um maior número de populações componentes.

Os dados podem ser transformados previamente ao cálculo da medida de semelhança. A transformação para *presença ou ausência* atribui 1 às populações componentes presentes ( $X_{i\alpha} > 0$ ) e zero às ausentes no inventário ( $X_{i\alpha} = 0$ ). Essa transformação dá um peso muito grande a populações que ocorrem em pequena quantidade. A *centralização* dentro de populações muda a origem do espaço de comparação mas não muda a configuração de pontos (veja Figura 2). A *normalização* pode alterar drasticamente a configuração de pontos. Alguns índices de semelhança envolvem transformações implícitas que modificam a configuração dos objetos no espaço de comparação. Entre esses, pode-se citar o índice de *correlação* e a *distância de corda*.




Figura 2. Efeito da centralização dos dados dentro de cada população componente ( $X_1$  e  $X_2$ ). A origem do espaço de comparação é deslocada para o ponto  $(\bar{X}_1, \bar{X}_2)$ . Note que as distâncias entre os pontos não se alteram.

Os dados a seguir se referem a 5 inventários de vegetação campestre (Pillar 1988, Pillar & Orlóci 1993). Nesses inventários foram encontrados 20 populações componentes (CSTs, linhas na matriz de dados, definidos por um conjunto de 5 caracteres), cujas quantidades estão indicadas. As quantidades foram obtidas por estimativa visual usando uma escala de 0 a 9. Os caracteres são formas de crescimento (g1 = 1:solitária, 2:roseta, 3:cespitosa; g3 = 1:estolonífera, 2:rizomatosa, 3:outra ), tipo de tecido do caule (st = 1:herbáceo, 2:lenhoso, 3:sem caule), forma da seção transversal da folha (cr = 1:reta, 2:dobrada, 3: enrolada, 4:outra), e largura da lâmina foliar (wi = 1:< 2.5 mm, 2:2.5-5, 3:5-10, 4:10-50, 5:50-100, 6:100<, 0:sem folhas)

CSTs	Caracteres					Inventários				
	g3	cr	g1	st	wi	a	b	c	m	k
1	3	2	3	3	2	5	3	2	5	0
2	2	1	1	3	2	5	0	7	0	0
3	3	3	3	3	1	5	2	3	2	0
4	3	1	1	1	3	2	3	3	2	0
5	3	1	1	3	2	3	2	6	5	0
6	1	2	1	3	3	5	5	0	0	5
7	3	1	1	1	1	2	1	2	3	0
8	2	1	1	3	3	0	8	0	2	0
9	1	1	1	1	4	0	3	0	0	0
10	2	1	2	3	2	0	1	0	0	0
11	3	1	1	3	3	0	1	2	0	0
12	3	1	2	3	3	0	2	1	0	5
13	3	2	3	3	1	0	0	5	0	0
14	2	1	1	1	3	0	0	1	0	0
15	3	1	1	2	4	0	0	3	3	1
16	1	1	2	1	4	0	0	0	0	5
17	3	1	3	3	1	0	0	0	0	5
18	3	2	1	3	2	0	0	0	0	5
19	2	1	2	3	3	0	0	0	3	0
20	3	1	3	3	2	0	0	0	1	0

A partir da matriz de dados pode ser calculado o índice de similaridade de Jaccard entre os inventários:

1	0.5	0.5	0.455	0.083
	1	0.467	0.429	0.133
		1	0.429	0.133
			1	0.071
				1

Nessa matriz, por exemplo, a similaridade entre os inventários "b" e "c"  $J_{bc} = 7/(7+4+4) = 0.467$ . Note que  $J_{aa} = J_{bb} = J_{cc} = J_{mm} = J_{kk} = 1$  (diagonal da matriz).

Com os mesmos dados, são calculadas dissimilaridades entre os inventários (função valor absoluto):

0	28	28	25	43
---	----	----	----	----



Nessa matrix, a dissimilaridade entre os CSTs 1 e 2 é  $d_{12} = |5-5| + |3-0| + |2-7| + |5-0| + |0-0| = 13$ .

### Classificação

A classificação revela tipos de comunidades ou tipos de populações componentes. Uma classificação pode ser obtida manualmente pelo rearranjo de linhas e colunas de uma tabela de vegetação, como em Braun-Blanquet (1964), ou automaticamente através de métodos numéricos. A classificação através de métodos numéricos (análise de agrupamentos ou de conglomerados) se baseia em uma matriz de semelhança contendo as similaridades ou dissimilaridades entre todos os pares de inventários envolvidos. Há vários métodos de análise de agrupamentos. O algoritmo é geralmente aglomerativo, através do qual grupos são obtidos pela agregação de inventários (ou grupos de inventários) mais semelhantes.


O método de aglomeração de *ligação simples* que usa o critério do vizinho mais próximo é o mais fácil de entender. Usando a matriz de dissimilaridades entre inventários do exemplo anterior, o primeiro passo do processo de aglomeração junta os inventários "a" e "m", que é o par que apresenta a menor dissimilaridade ( $d_{am} = 25$ ) entre todos os demais pares. A segunda menor dissimilaridade é 28, para  $d_{ab}$  e  $d_{ac}$ . O algoritmo arbitrariamente toma  $d_{ab}$  (aparece antes na matriz), e como o inventário "a" já está agrupado com o "m", o segundo passo junta o grupo a+m ao inventário b. A seguir (3º passo) o algoritmo toma  $d_{ac}$  como a menor dissimilaridade e junta o grupo a+m+b ao inventário c. A próxima menor dissimilaridade envolvendo inventários não pertencentes ao mesmo grupo é  $d_{ak}$  e  $d_{bk} = 43$ . O 4º e último passo, portanto, junta o inventário k ao grupo a+m+b+c.

Matriz de dissimilaridade (função valor absoluto):

	a	b	c	m	k
a	0	28	28	25	43
b		0	42	33	43
c			0	29	57
m				0	50
k					0


Passo	Dissimilaridade	Inventários agrupados				
1	25	a	m			
2	28	a	m	b		
3	28	a	m	b	c	
4	43	a	m	b	c	k

A classificação é representada graficamente em um dendrograma. A distância na horizontal indica o grau de dissimilaridade no qual o passo de aglomeração ocorreu. O nosso exemplo gerou o seguinte dendrograma:




A análise de agrupamentos pode também ser aplicada a populações componentes. Nesse caso, a matriz de semelhança compara populações componentes e o processo aglomerativo é o mesmo. Usando o mesmo exemplo, obtém-se os seguintes resultados:

Passo	Dissimilaridade	Populações agrupadas									
1	0	16	17								
2	0	16	17	18							
3	2	9	10								
4	2	9	10	11							
5	2	9	10	11	14						
6	2	9	10	11	14	20					
7	2	9	10	11	14	20	19				
8	3	12	16	17	18						
9	4	3	4								
10	4	3	4	7							
11	4	9	10	11	14	20	19	13			
12	4	9	10	11	14	20	19	13	15		
13	5	1	3	4	7						
14	5	1	3	4	7	9	10	11	14	20	
		19	13	15							
15	6	1	3	4	7	9	10	11	14	20	
		19	13	15	12	16	17	18			
16	7	1	3	4	7	9	10	11	14	20	
		19	13	15	12	16	17	18	2		
17	7	1	3	4	7	9	10	11	14	20	
		19	13	15	12	16	17	18	2		
		5									
18	7	1	3	4	7	9	10	11	14	20	
		19	13	15	12	16	17	18	2		
		5	8								
19	9	1	3	4	7	9	10	11	14	20	
		19	13	15	12	16	17	18	2		
		5	8	6							




O método de aglomeração pelo vizinho mais próximo tem a desvantagem de definir grupos em cadeia. Os métodos de aglomeração pelo critério da *ligação completa* e pelo da *soma de quadrados* ou *variância mínima* (descritos em Pielou 1984, Wildi & Orłóci 1990 e Orłóci & Kenkel 1985), podem produzir melhores resultados. Com o mesmo exemplo anterior, os dendrogramas resultantes são os seguintes:

Dendrograma de inventários:



Dendrograma de populações componentes:





Note que o resultado da análise de agrupamentos não é uma partição em grupos, mas várias possibilidades de partição. Assim, no dendrograma de inventários acima pode-se ter desde apenas 1 grupo com 5 indivíduos até 5 "grupos" com 1 indivíduo. O problema é decidir onde traçar a "linha de corte" no dendrograma. No exemplo, parece ser razoável definir uma partição de 3 grupos de inventários ("a+m+c", "b" e "k") e 3 grupos de componentes.

As linhas e colunas da tabela original de dados podem ser rearranjadas segundo grupos de inventários e grupos de componentes, constituindo uma tabela estruturada. Nesta podem ser identificados blocos de grupos de populações componentes que caracterizam cada grupo de inventários. Veja o exemplo como fica:

CST	Gr	a 1	c 1	m 1	b 2	k 3
1	1	5	2	5	3	0
2	1	5	7	0	0	0
3	1	5	3	2	2	0
4	1	2	3	2	3	0
5	1	3	6	5	2	0
13	1	0	5	0	0	0
6	2	5	0	0	5	5
12	2	0	1	0	2	5
16	2	0	0	0	0	5
17	2	0	0	0	0	5
18	2	0	0	0	0	5
7	3	2	2	3	1	0
8	3	0	0	2	8	0
9	3	0	0	0	3	0
10	3	0	0	0	1	0
11	3	0	2	0	1	0
14	3	0	1	0	0	0
15	3	0	3	3	0	1
19	3	0	0	3	0	0
20	3	0	0	1	0	0

A tabela estruturada evidencia que os componentes do grupo 1 caracterizam o grupo 1 de inventários e, embora de forma ambígua, que os componentes do grupo 2 caracterizam o grupo 3 de inventários, e os componentes do grupo 3 caracterizam o grupo 2 de inventários.

### *Ordenação*

A ordenação é o arranjo de objetos em uma ordem uni ou multidimensional. Ordenação unidimensional consiste em ordenar objetos com base em um critério, por exemplo, inventários em ordem crescente de cobertura de uma dada espécie, ou em ordem crescente de pH do solo. A análise de gradientes de Whittaker (1967) é um tipo de ordenação direta e unidimensional; são dadas notas às espécies com base em sua preferência de condições em um gradiente de ambiente evidente e aparentemente importante; os inventários são então ordenados pela média das notas das espécies neles ocorrentes.

A ordenação mais comumente tratada em análise é multidimensional, e produz uma síntese do espaço de comparação em um menor número de dimensões, chamadas componentes ou coordenadas principais. Estas passam pelas zonas de maior variação no espaço de comparação original (veja Figura 3). Os objetos ordenados podem ser inventários ou populações componentes.

Como normalmente as variáveis que descrevem comunidades estão correlacionadas entre si, há um certo grau de redundância. Portanto, as primeiras coordenadas principais poderão conter grande parte da informação dos dados. Pode-se assim representar o espaço de comparação, que antes era complexo, hiperdimensional, em um espaço mais facilmente interpretável, de 2 ou 3 dimensões em um diagrama de dispersão, sem muita perda de informação. Os diagramas de dispersão revelam padrões de distribuição de inventários e/ou

de populações componentes no espaço abstrato e possíveis relações destes com a variação espaço-temporal de fatores de ambiente.




Figura 3. Espaço de comparação de inventários definido por 2 dimensões ( $X_1$  e  $X_2$ ). A ordenação redefine o mesmo espaço através de 2 variáveis (I e II) que passam pela zona de maior densidade de pontos. A primeira variável (coordenada principal I) contém mais informação. A segunda (II) é ortogonal à primeira e fica com o resíduo.

Há vários métodos de ordenação, e todos tendem a reproduzir resultados similares ao mostrado na Figura 3. O método de ordenação chamado de *ordenação simples*, proposto por Bray & Curtis (1957), é baseado em inventários de referência, que são os pontos extremos do espaço de comparação, por sobre os quais são traçados os novos eixos do espaço de comparação simplificado. Após traçado o primeiro eixo, um novo inventário de referência é escolhido entre os inventários remanescentes, passando por ele um segundo eixo ortogonal ao primeiro, e assim sucessivamente. A vantagem desse método é a simplicidade, não exigindo computador, porém toda a ordenação depende da posição de alguns pontos de referência, os quais nem sempre são de fácil escolha. O método é raramente usado atualmente.

Na ordenação, a síntese mais eficiente é obtida quando a relação entre as distâncias no novo eixo e as distâncias originais entre inventários é a máxima possível no primeiro eixo, e quando cada eixo subsequente obedece esse requerimento em relação à variável residual. Essa condição pode ser obtida através da técnica de ordenação chamada *análise de componentes principais* de Hotelling (1933) (veja descrição em Orlóci & Kenkel 1985). Basicamente, o método consiste em extrair as raízes ("eigenvalues") e respectivos vetores próprios ("eigenvectors") da matriz de momentos produtos, de covariância ou de correlação entre as variáveis originais; os vetores próprios são os redescritores do novo espaço de comparação, e o grau de síntese é indicado pelas raízes; quanto maior o valor relativo da raiz, maior é a variação contida no vetor próprio. Aplicando análise de componentes principais ao nosso exemplo obtem-se os seguintes resultados:


Raízes: 148.937 88.7616 42.8053 34.2958  
 Percentagem: 47.3 28.2 13.6 10.9  
 Escores de inventários nos primeiros 4 componentes (usados no diagrama de dispersão):

	a	b	c	m	k
Eixo 1:	-2.55276	2.14041	-6.29414	-2.8004	9.50689
Eixo 2:	0.308502	-7.0511	4.39991	-1.73082	4.07351
Eixo 3:	-3.83843	-1.36254	-0.391405	5.07925	0.513122
Eixo 4:	3.75429	-2.38415	-3.27283	1.95018	-0.0474938

Correlação entre os eixos de ordenação e os CSTs:

CSTs	Eixo 1	Eixo 2	Eixo 3	Eixo 4
1	-0.63605	-0.486976	0.048047	0.596646
2	-0.69255	0.510603	-0.498609	-0.105109
3	-0.743498	-0.0824319	-0.544078	0.379992
4	-0.775001	-0.467911	-0.17348	-0.387735
5	-0.946306	0.101557	0.281925	-0.121284
6	0.680281	-0.258619	-0.654084	0.206174
7	-0.860767	-0.131574	0.362987	0.331677
8	0.136277	-0.917232	-0.0163648	-0.37396
9	0.196087	-0.836757	-0.232838	-0.455164
10	0.196087	-0.836757	-0.232838	-0.455164
11	-0.478576	0.103761	-0.183305	-0.852407
12	0.899388	0.272957	-0.0203018	-0.340857
13	-0.57662	0.522139	-0.0668856	-0.624825
14	-0.57662	0.522139	-0.0668856	-0.624825
15	-0.480238	0.422755	0.734539	-0.226058
16	0.870947	0.483405	0.0876853	-0.00906716
17	0.870947	0.483405	0.0876853	-0.00906716
18	0.870947	0.483405	0.0876853	-0.00906716
19	-0.256551	-0.205397	0.867972	0.372315
20	-0.256551	-0.205397	0.867972	0.372315

Diagrama de dispersão com os 2 primeiros componentes principais (eixo I na horizontal, eixo 2 na vertical):



O diagrama de dispersão acima reproduz a estrutura de grupos revelada pela análise de agrupamentos, ou seja, pode-se distinguir 3 grupos ("a+m+c", "b", e "k"). Além disso, o diagrama pode ser interpretado em relação a variáveis de ambiente. Assim, a variável de ambiente com a mais alta correlação com o eixo I é umidade do solo, ou seja, há um

gradiente de umidade crescente associado à variação da vegetação da esquerda para a direita do diagrama.

Existem outros métodos de ordenação, tais como a *análise de correspondência* ou *análise de tabelas de contingência* (Benzecri 1969, Feoli & Orlóci 1979), a *análise de coordenadas principais* ou simplesmente *ordenação com extração de raízes próprias* (Gower 1966, Pillar & Orlóci 1993), e MDSCAL ("non-metric multidimensional scaling", Kenkel & Orlóci 1986).

### *Bibliografia citada*

- Benzecri, J. P. 1969. Statistical analysis as a tool to make patterns emerge from data. In: Watanabe, S. (ed.). *Methodologies of Pattern Recognition*. p. 35-74. Academic Press, New York.
- Braun-Blanquet, J. 1964. *Fitosociologia; bases para el estudio de las comunidades vegetales*. Trad. da 3.ed.rev.aum. Blume, Madrid, 1979. 820 p.
- Bray, J. R. & J. T. Curtis. 1957. An ordination of the upland forest communities of southern Wisconsin. *Ecological Monographs* 27: 325-49.
- Digby, P. G. N. & Kempton, R. A. 1987. *Multivariate Analysis of Ecological Communities*. London, Chapman & Hall. 206 p.
- Feoli, E. & L. Orlóci. 1979. Analysis of concentration and detection of underlying factors in structure tables. *Vegetatio* 40: 49-54.
- Feoli, E. & L. Orlóci (eds.). 1991. *Computer Assisted Vegetation Analysis*. Kluwer, Dordrecht. 498 p.
- Gower, J. C. 1966. Some distance properties of latent root and vector methods used in multivariate analysis. *Biometrika* 53: 325-338
- Kenkel, N. & L. Orlóci. 1986. Applying metric and nonmetric multidimensional scaling to ecological studies: some new results. *Ecology* 67: 919-28.
- Mueller-Dombois, D. & H. Ellenberg. 1974. *Aims and Methods of Vegetation Ecology*. Wiley, New York. 547 p.
- Orlóci, L. 1978. *Multivariate Analysis in Vegetation Research*. 2. ed. Junk, The Hague. 451 p.
- Orlóci, L. 1991. Poorean approximation and fisherian inference in bioenvironmental analysis. *Advances in Ecology* 1: 65-71.
- Orlóci, L. & M. Orlóci. 1985. Comparison of communities without the use of species: model and example. *Annali di Botanica* 43: 275-285.
- Orlóci, L. & N. Kenkel. 1985. *Introduction to Data Analysis*. International Co-operative Publishing House, Fairland, Maryland. 340 p.
- Pielou, E. C. 1984. *The Interpretation of Ecological Data; a Primer on Classification and Ordination*. New York, J. Wiley. 263 p.
- Pillar, V. D. P. 1988. *Fatores de Ambiente Relacionados à Variação da Vegetação de um Campo Natural*. Dissertação de Mestrado, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS. 164 p.
- Pillar, V. D. P. & L. Orlóci. 1993. *Character-Based Community Analysis: The Theory and an Application Program*. SPB Academic Publishing, The Hague. 270 p.
- Podani, J. 1994. *Multivariate Data Analysis in Ecology and Systematics*. The Hague, SPB Academic Publishing. 316 p.

- Poore, M. E. D. 1962. The method of successive approximation in descriptive ecology. *Advances in Ecological Research* 1: 35-68.
- Whittaker, R. H. 1967. Gradient analysis of vegetation. *Biological Reviews* 42: 207-64.
- Whittaker, R. H. (ed.). 1973. *Ordination and Classification*. Junk, The Hague. 737 p.
- Wildi, O. & L. Orłóci. 1987. Flexible gradient analysis: a note on ideas and example. *Coenoses* 2: 61-65.
- Wildi, O. & L. Orłóci. 1990. *Numerical Exploration of Community Patterns*. SPB Academic Publishing, The Hague. 124 p.