

# Morte súbita dos citros: uma abordagem de modelos Markovianos latentes

Silvia Shimakura

LEG-Universidade Federal do Paraná  
*silvia.shimakura@ufpr.br*

26 de Outubro de 2006

# Agradecimentos

- FUNDECITRUS
- Renato Bassanezzi (FUNDECITRUS)
- Paulo Justiniano Ribeiro Jr (UFPR)
- Elias Krainski (UFMG)

# Conteúdo

- Suposições em análise de sobrevivência clássica

# Conteúdo

- Suposições em análise de sobrevivência clássica
- **Motivação**

# Conteúdo

- Suposições em análise de sobrevivência clássica
- Motivação
- Modelos Markovianos latentes

# Conteúdo

- Suposições em análise de sobrevivência clássica
- Motivação
- Modelos Markovianos latentes
- **Aplicação**

# Conteúdo

- Suposições em análise de sobrevivência clássica
- Motivação
- Modelos Markovianos latentes
- Aplicação
- **Considerações**

## Suposições em análise de sobrevivência clássica

Aceitáveis para *morte* e muitas *doenças crônicas*:

- Sujeitos são *saudáveis* ou *doentes*, sem estágios intermediários;



## Suposições em análise de sobrevivência clássica

Aceitáveis para *morte* e muitas *doenças crônicas*:

- Sujeitos são *saudáveis* ou *doentes*, sem estágios intermediários;
- O tempo de incidência e evolução da doença é conhecido exatamente;

## Suposições em análise de sobrevivência clássica

Aceitáveis para *morte* e muitas *doenças crônicas*:

- Sujeitos são *saudáveis* ou *doentes*, sem estágios intermediários;
- O tempo de incidência e evolução da doença é conhecido exatamente;
- **A doença é diagnosticada sem erro.**

## A doença é dicotômica?

- A doença pode ser classificada em graus de severidade (leve, moderada, severa)

## A doença é dicotômica?

- A doença pode ser classificada em graus de severidade (leve, moderada, severa)
- A doença pode ser precedida de uma fase sub-clínica antes de mostrar seus sintomas.

## Exemplo: Modelo para adenocarcinoma gástrico

- O desenvolvimento de câncer gástrico demora muitas décadas.

Normal  $\leftrightarrow$  GS  $\leftrightarrow$  GC  $\leftrightarrow$  GCA  $\leftrightarrow$  MI  $\leftrightarrow$  Displasia  $\rightarrow$  Câncer

## Exemplo: Modelo para adenocarcinoma gástrico

- O desenvolvimento de câncer gástrico demora muitas décadas.

Normal  $\leftrightarrow$  GS  $\leftrightarrow$  GC  $\leftrightarrow$  GCA  $\leftrightarrow$  MI  $\leftrightarrow$  Displasia  $\rightarrow$  Câncer

- Uma gastroscopia é necessária para diagnose de lesões pré-câncer.

## Exemplo: Modelo para câncer cervical

- Câncer cervical é precedido por neoplasia cervical intraepitelial (NCI)

Normal  $\leftrightarrow$  NCI I  $\leftrightarrow$  NCI II  $\leftrightarrow$  NCI III  $\rightarrow$  Câncer

## Exemplo: Modelo para câncer cervical

- Câncer cervical é precedido por neoplasia cervical intraepitelial (NCI)

Normal $\leftrightarrow$ NCI I $\leftrightarrow$ NCI II $\leftrightarrow$ NCI III $\rightarrow$ Câncer

- O propósito de um programa de varredura é detectar e tratar NCI.



# Da epidemiologia de gente para a epidemiologia de plantas

- Morte Súbita dos Citros

Sadia → Estágio Inicial → Estágio Avançado → Morte

# Da epidemiologia de gente para a epidemiologia de plantas

- Morte Súbita dos Citros

Sadia → Estágio Inicial → Estágio Avançado → Morte

- Doença progressiva sem possibilidade de cura

## Quando ocorre o evento?

- Podem ser necessárias visitas clínicas para diagnose da doença:

## Quando ocorre o evento?

- Podem ser necessárias visitas clínicas para diagnose da doença:
  - **exame médico, ou**

## Quando ocorre o evento?

- Podem ser necessárias visitas clínicas para diagnose da doença:
  - exame médico, ou
  - testes laboratoriais em amostras de sangue, ou

## Quando ocorre o evento?

- Podem ser necessárias visitas clínicas para diagnose da doença:
  - exame médico, ou
  - testes laboratoriais em amostras de sangue, ou
  - **biópsia feita por patologista.**

## Quando ocorre o evento?

- Podem ser necessárias visitas clínicas para diagnose da doença:
  - exame médico, ou
  - testes laboratoriais em amostras de sangue, ou
  - biópsia feita por patologista.
- Não se sabe o que acontece entre visitas consecutivas (censura intervalar)

## Conhecemos o verdadeiro estatus da doença?

- Diagnóstico correto pode requerer procedimento invasivo.



## Conhecemos o verdadeiro estatus da doença?

- Diagnóstico correto pode requerer procedimento invasivo.
- Diagnóstico preciso pode requerer um painel de consenso.

## Conhecemos o verdadeiro estatus da doença?

- Diagnóstico correto pode requerer procedimento invasivo.
- Diagnóstico preciso pode requerer um painel de consenso.
- **Biomarcadores podem ter erros aleatórios.**

## Conhecemos o verdadeiro estatus da doença?

- Diagnóstico correto pode requerer procedimento invasivo.
- Diagnóstico preciso pode requerer um painel de consenso.
- Biomarcadores podem ter **erros aleatórios**.
- **Estados observados com erros de classificação**.


## Modelos multi-estados

Terminologia de análise de sobrevivência é convertida:

Estatus caso/controlado	→	Estados da doença
Incidência da doença	→	Transições entre estados
Taxa de incidência	→	Intensidades de transição

## Modelos multi-estados em tempo contínuo

- Indivíduo move-se através de estados segundo um processo  $S(t)$  em tempo contínuo com matriz de intensidade  $Q$ .
- **Exemplo:** Modelo multi-estados em tempo contínuo com 4 estados



## Intensidades de transição

- O elemento  $(r, s)$  de  $Q$  representa o risco instantâneo de progressão para o estado  $s$ , tendo ocupado o estado  $r$

$$q_{rs}(t, F_t) = \lim_{\delta t \rightarrow 0} Pr(S(t + \delta t) = s | S(t) = r, F_t^-) / \delta t,$$

em que  $F_t^-$  é história observada do processo até o tempo  $t^-$ .

## Intensidades de transição

- O elemento  $(r, s)$  de  $Q$  representa o risco instantâneo de progressão para o estado  $s$ , tendo ocupado o estado  $r$

$$q_{rs}(t, F_t) = \lim_{\delta t \rightarrow 0} Pr(S(t + \delta t) = s | S(t) = r, F_t^-) / \delta t,$$

em que  $F_t^-$  é história observada do processo até o tempo  $t^-$ .

- Quando o processo é homogêneo e markoviano

$$q_{rs}(t, F_t) = q_{rs}$$

## Probabilidades de transição

- Em processos markovianos, a probabilidade de transição do estado  $r$  no tempo  $v$  para o estado  $s$  no tempo  $u$  é

$$p_{rs}(v, u) = Pr\{S(u) = s | S(v) = r\}$$



## Probabilidades de transição

- Em processos markovianos, a probabilidade de transição do estado  $r$  no tempo  $v$  para o estado  $s$  no tempo  $u$  é

$$p_{rs}(v, u) = Pr\{S(u) = s | S(v) = r\}$$

- Em processos markovianos e homogêneos

$$p_{rs}(v, u) = p_{rs}(0, u - v) = p_{rs}(t)(t = u - v)$$

## Probabilidades de transição

- Em processos markovianos, a probabilidade de transição do estado  $r$  no tempo  $v$  para o estado  $s$  no tempo  $u$  é

$$p_{rs}(v, u) = Pr\{S(u) = s | S(v) = r\}$$

- Em processos markovianos e homogêneos

$$p_{rs}(v, u) = p_{rs}(0, u - v) = p_{rs}(t)(t = u - v)$$

- Estas formam uma matriz de probabilidades de transição  $P(t)$

$$P(t) = \exp(Qt) = \sum_{r=0}^{\infty} Q^r t^r / r!$$

## Probabilidades de transição

- Em processos markovianos, a probabilidade de transição do estado  $r$  no tempo  $v$  para o estado  $s$  no tempo  $u$  é

$$p_{rs}(v, u) = Pr\{S(u) = s | S(v) = r\}$$

- Em processos markovianos e homogêneos

$$p_{rs}(v, u) = p_{rs}(0, u - v) = p_{rs}(t) (t = u - v)$$

- Estas formam uma matriz de probabilidades de transição  $P(t)$

$$P(t) = \exp(Qt) = \sum_{r=0}^{\infty} Q^r t^r / r!$$

- Expressões analíticas podem ser obtidas para modelos de até 5 estados.

## Probabilidades de transição

- Em processos markovianos, a probabilidade de transição do estado  $r$  no tempo  $v$  para o estado  $s$  no tempo  $u$  é

$$p_{rs}(v, u) = Pr\{S(u) = s | S(v) = r\}$$

- Em processos markovianos e homogêneos


$$p_{rs}(v, u) = p_{rs}(0, u - v) = p_{rs}(t) \quad (t = u - v)$$

- Estas formam uma matriz de probabilidades de transição  $P(t)$

$$P(t) = \exp(Qt) = \sum_{r=0}^{\infty} Q^r t^r / r!$$


- Expressões analíticas podem ser obtidas para modelos de até 5 estados.
- Verossimilhança pode ser calculada a partir de  $P(t)$  (Cox & Miller, 1965).

## Modelos progressivos




- Representa uma série de estados sucessivamente mais graves e um estado "absorvente".

## Modelos progressivos



- Representa uma série de estados sucessivamente mais graves e um estado "absorvente".
- O paciente pode avançar para ou regredir de estados adjacentes ou morrer a partir de qualquer estado.

# Modelos progressivos



- Representa uma série de estados sucessivamente mais graves e um estado "absorvente".
- O paciente pode avançar para ou regredir de estados adjacentes ou morrer a partir de qualquer estado.
- **Observação do processo  $S(t)$  pode ser tomada em qualquer tempo arbitrário  $t$  (que pode variar entre indivíduos).**

## Matriz de transição

- Os estágios da doença podem ser modelados segundo um **processo markoviano homogêneo em tempo contínuo**, com matriz de transição  $Q$

$$Q = \begin{pmatrix} q_{11} & q_{12} & 0 & 0 & \cdots & q_{1n} \\ q_{21} & q_{22} & q_{23} & 0 & \cdots & q_{2n} \\ 0 & q_{32} & q_{33} & q_{34} & \ddots & q_{3n} \\ 0 & 0 & q_{43} & q_{44} & \ddots & q_{4n} \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & 0 \end{pmatrix}$$

- Elementos diagonais:  $q_{rr} = -\sum_{s \neq r} q_{rs}$



## Modelos Markovianos latentes

- Para um indivíduo  $i$ , tempo de observação  $t_{ij}$ ,  $S_{ij} = S_i(t_{ij})$  representa o verdadeiro estado do indivíduo  $i$  no tempo  $t_{ij}$ , e  $O_{ij}$  representa o estado observado.

## Modelos Markovianos latentes

- Para um indivíduo  $i$ , tempo de observação  $t_{ij}$ ,  $S_{ij} = S_i(t_{ij})$  representa o verdadeiro estado do indivíduo  $i$  no tempo  $t_{ij}$ , e  $O_{ij}$  representa o estado observado.
- $O_{ij}$  são gerados condicionalmente a  $S_{ij}$  de acordo com uma matriz de erros de classificação  $E$ , com elemento  $(r, s)$

$$e_{rs} = Pr(O(t_{ij}) = s | S(t_{ij}) = r)$$

(independente do tempo  $t$ ).

## Modelos Markovianos latentes

- Para um indivíduo  $i$ , tempo de observação  $t_{ij}$ ,  $S_{ij} = S_i(t_{ij})$  representa o verdadeiro estado do indivíduo  $i$  no tempo  $t_{ij}$ , e  $O_{ij}$  representa o estado observado.
- $O_{ij}$  são gerados condicionalmente a  $S_{ij}$  de acordo com uma matriz de erros de classificação  $E$ , com elemento  $(r, s)$

$$e_{rs} = Pr(O(t_{ij}) = s | S(t_{ij}) = r)$$

(independente do tempo  $t$ ).

- $e_{rs}$  refletem conhecimento do processo de latente. Ex.  $e_{rs}$  pequeno para estados não adjacentes.

## Efeitos de covariáveis

- Na intensidade de transição:

## Efeitos de covariáveis

- Na intensidade de transição:
  - Riscos proporcionais para relacionar as intensidades de transição  $q_{rs}(t)$  no tempo  $t$  a covariáveis  $x(t)$

$$q_{rs}\{t, x(t)\} = q_{rs} \exp\{\beta'_{rs} x(t)\}$$

## Efeitos de covariáveis

- Na intensidade de transição:
  - **Riscos proporcionais** para relacionar as intensidades de transição  $q_{rs}(t)$  no tempo  $t$  a covariáveis  $x(t)$

$$q_{rs}\{t, x(t)\} = q_{rs} \exp\{\beta'_{rs} x(t)\}$$

- Cada transição pode ter uma intensidade de base diferente

## Efeitos de covariáveis

- Na intensidade de transição:
  - **Riscos proporcionais** para relacionar as intensidades de transição  $q_{rs}(t)$  no tempo  $t$  a covariáveis  $x(t)$

$$q_{rs}\{t, x(t)\} = q_{rs} \exp\{\beta'_{rs} x(t)\}$$

- Cada transição pode ter uma intensidade de base diferente
- **Na probabilidade de erro de classificação:**

## Efeitos de covariáveis

- Na intensidade de transição:
  - **Riscos proporcionais** para relacionar as intensidades de transição  $q_{rs}(t)$  no tempo  $t$  a covariáveis  $x(t)$

$$q_{rs}\{t, x(t)\} = q_{rs} \exp\{\beta'_{rs}x(t)\}$$

- Cada transição pode ter uma intensidade de base diferente
- Na probabilidade de erro de classificação:
  - **Modelo logístico** para relacionar as probabilidades de erro de classificação  $e_{rs}$  a covariáveis  $w(t)$

$$\log \frac{e_{rs}(t)}{1 - e_{rs}(t)} = \gamma'_{rs}w(t)$$



# Verossimilhança

- Método direto baseado em produtos de matrizes (Macdonald e Zucchini, 1997).
- Contribuição do indivíduo  $i$  para a verossimilhança é

$$\begin{aligned}L_i &= Pr(O_{i1}, \dots, O_{im_i}) \\ &= \sum_{S_{i1}, \dots, S_{im_i}} Pr(O_{i1}, \dots, O_{im_i} | S_{i1}, \dots, S_{im_i}) Pr(S_{i1}, \dots, S_{im_i})\end{aligned}$$

# Verossimilhança

- Assumindo independência condicional entre estados observados dado  $S_i$  e a propriedade markoviana

$$Pr(S_{ij}|S_{i(j-1)}, \dots, S_{i1}) = Pr(S_{ij}|S_{i(j-1)})$$

# Verossimilhança

- Assumindo independência condicional entre estados observados dado  $S_i$  e a propriedade markoviana

$$Pr(S_{ij}|S_{i(j-1)}, \dots, S_{i1}) = Pr(S_{ij}|S_{i(j-1)})$$



$$L_j = \sum_{S_{i1}} Pr(O_{i1}|S_{i1})Pr(S_{i1}) \sum_{S_{i2}} Pr(O_{i2}|S_{i2})Pr(S_{i2}|S_{i1}) \\ \dots \sum Pr(O_{im_i}|S_{im_i})Pr(S_{im_i}|S_{i(m_i-1)})$$

# Verossimilhança

- Assumindo independência condicional entre estados observados dado  $S$ ; e a propriedade markoviana

$$Pr(S_{ij}|S_{i(j-1)}, \dots, S_{i1}) = Pr(S_{ij}|S_{i(j-1)})$$

- 

$$L_i = \sum_{S_{i1}} Pr(O_{i1}|S_{i1})Pr(S_{i1}) \sum_{S_{i2}} Pr(O_{i2}|S_{i2})Pr(S_{i2}|S_{i1}) \\ \dots \sum Pr(O_{im_i}|S_{im_i})Pr(S_{im_i}|S_{i(m_i-1)})$$

- $Pr(O_{ij}|S_{ij}) = e_{S_{ij}O_{ij}}$

# Verossimilhança

- Assumindo independência condicional entre estados observados dado  $S_i$  e a propriedade markoviana

$$Pr(S_{ij}|S_{i(j-1)}, \dots, S_{i1}) = Pr(S_{ij}|S_{i(j-1)})$$

- 

$$L_i = \sum_{S_{i1}} Pr(O_{i1}|S_{i1})Pr(S_{i1}) \sum_{S_{i2}} Pr(O_{i2}|S_{i2})Pr(S_{i2}|S_{i1}) \\ \dots \sum Pr(O_{im_i}|S_{im_i})Pr(S_{im_i}|S_{i(m_i-1)})$$

- $Pr(O_{ij}|S_{ij}) = e_{S_{ij}O_{ij}}$
- $Pr(S_{i(j+1)}|S_{ij})$  é o elemento  $(S_{ij}, S_{i(j+1)})$  de  $P(t)$  avaliada em  $t = t_{i(j+1)} - t_{ij}$

# Verossimilhança

- $L_i$  pode ser escrita como produto de matrizes

$$L_i = f T_{i2} T_{i3} \cdots T_{im_i} 1$$

# Verossimilhança

- $L_i$  pode ser escrita como produto de matrizes

$$L_i = \mathbf{f} T_{i2} T_{i3} \cdots T_{im_i} \mathbf{1}$$

- **f**: vetor de probabilidades de ocupação no estágio inicial  $Pr(S_{i1})$ .

# Verossimilhança

- $L_i$  pode ser escrita como produto de matrizes

$$L_i = \mathbf{f} T_{i2} T_{i3} \cdots T_{im_i} \mathbf{1}$$

- $\mathbf{f}$ : vetor de probabilidades de ocupação no estágio inicial  $Pr(S_{i1})$ .
- $T_{ij}$  ( $j = 2, \dots, m_i$ ): matriz ( $n \times n$ ) com elemento  $(r, s)$

$$T_{ij} = e_{s0_{ij}} p_{rs}(t_{ij} - t_{i(j-1)})$$



# Verossimilhança

- $L_i$  pode ser escrita como produto de matrizes

$$L_i = \mathbf{f} T_{i2} T_{i3} \cdots T_{im_i} \mathbf{1}$$

- $\mathbf{f}$ : vetor de probabilidades de ocupação no estágio inicial  $Pr(S_{i1})$ .
- $T_{ij}$  ( $j = 2, \dots, m_i$ ): matriz ( $n \times n$ ) com elemento  $(r, s)$

$$T_{ij} = e_{sO_{ij}} p_{rs}(t_{ij} - t_{i(j-1)})$$

- Métodos numéricos usados para maximizar a verossimilhança e obter erros padrão aproximados da inversa do Hessiano, estimada por diferenças finitas.

# Implementação

- Christopher Jackson (2006). `msm`: Multi-state Markov and hidden Markov models in continuous time. R package version 0.6.3.

## Aplicação: Modelo com 4 estados e erros de classificação para MSC

- O risco de transição depende do estágio atual da doença e de características ambientais?

## Aplicação: Modelo com 4 estados e erros de classificação para MSC

- O risco de transição depende do estágio atual da doença e de características ambientais?
- **Matriz intensidade de transição**

$$Q = \begin{pmatrix} -q_{12} & q_{12} & 0 & 0 \\ 0 & -q_{23} & q_{23} & 0 \\ 0 & 0 & -q_{34} & q_{34} \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

## Aplicação: Modelo com 4 estados e erros de classificação para MSC

- O risco de transição depende do estágio atual da doença e de características ambientais?
- Matriz intensidade de transição

$$Q = \begin{pmatrix} -q_{12} & q_{12} & 0 & 0 \\ 0 & -q_{23} & q_{23} & 0 \\ 0 & 0 & -q_{34} & q_{34} \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

- Covariáveis: idade, estação do ano.

# Aplicação: Modelo com 4 estados e erros de classificação para MSC

- Matriz de erros de classificação

$$E = \begin{pmatrix} 1 - e_{12} & e_{12} & 0 & 0 \\ e_{21} & 1 - e_{21} - e_{23} & e_{23} & 0 \\ 0 & e_{32} & 1 - e_{32} - e_{34} & e_{34} \\ 0 & 0 & e_{43} & 1 - e_{43} \end{pmatrix}$$

## Aplicação: Modelo com 4 estados e erros de classificação para MSC

- Matriz de erros de classificação

$$E = \begin{pmatrix} 1 - e_{12} & e_{12} & 0 & 0 \\ e_{21} & 1 - e_{21} - e_{23} & e_{23} & 0 \\ 0 & e_{32} & 1 - e_{32} - e_{34} & e_{34} \\ 0 & 0 & e_{43} & 1 - e_{43} \end{pmatrix}$$

- Covariáveis: estação do ano

## Aplicação: Modelo com 4 estados e erros de classificação para MSC

- Matriz de erros de classificação

$$E = \begin{pmatrix} 1 - e_{12} & e_{12} & 0 & 0 \\ e_{21} & 1 - e_{21} - e_{23} & e_{23} & 0 \\ 0 & e_{32} & 1 - e_{32} - e_{34} & e_{34} \\ 0 & 0 & e_{43} & 1 - e_{43} \end{pmatrix}$$

- Covariáveis: estação do ano
- Vetor de probabilidades iniciais:

$$Pr(S_{i1}) = (0, 95; 0, 02; 0, 02; 0, 01)$$



## Resultados: transição

- Estimativas de parâmetros e I.C. 95%: Variedade Valência

Parâmetros	Transição	
Outono	$\hat{\beta}_{12}$	1.611 (1.469,1.753)
	$\hat{\beta}_{23}$	0.275 (0.109,0.442)
	$\hat{\beta}_{34}$	0.962 (0.770,1.154)
Inverno	$\hat{\beta}_{12}$	1.746 (1.616,1.876)
	$\hat{\beta}_{23}$	0.924 (0.782,1.067)
	$\hat{\beta}_{34}$	0.862 (0.686,1.037)
Primavera	$\hat{\beta}_{12}$	1.321 (1.182,1.459)
	$\hat{\beta}_{23}$	1.120 (0.960,1.280)
	$\hat{\beta}_{34}$	0.516 (0.305,0.727)
Idade	$\hat{\beta}_{12}$	0.269 (0.257,0.281)
	$\hat{\beta}_{23}$	-0.063 (-0.080,-0.045)
	$\hat{\beta}_{34}$	0.168 (0.140,0.197)

## Resultados: erros de classificação

- Estimativas de parâmetros e I.C. 95%: Variedade Valência

Parâmetros	Erros de classificação
Outono	$\hat{\gamma}_{12}$ -2.18 (-3.4,-0.96)*
	$\hat{\gamma}_{21}$ -1.04 (-1.25,-0.82)*
	$\hat{\gamma}_{23}$ -2.18 (-2.64,-1.71)*
	$\hat{\gamma}_{32}$ -0.49 (-1.14,0.15)
Inverno	$\hat{\gamma}_{12}$ -1.20 (-1.91,-0.49)*
	$\hat{\gamma}_{21}$ -0.20 (-0.38,-0.01)*
	$\hat{\gamma}_{23}$ -1.44 (-1.84,-1.03)*
	$\hat{\gamma}_{32}$ -0.47 (-1.19,0.24)
Primavera	$\hat{\gamma}_{12}$ 0.02 (-0.43,0.48)
	$\hat{\gamma}_{21}$ 0.10 (-0.09,0.29)
	$\hat{\gamma}_{23}$ 0.02 (-0.26,0.30)
	$\hat{\gamma}_{32}$ -1.60 (-2.50,-0.69)*

## Algumas considerações

- Modelos markovianos com erros de classificação em tempo-contínuo abrangem uma grande classe de problemas

## Algumas considerações

- Modelos markovianos com erros de classificação em tempo-contínuo abrangem uma grande classe de problemas
- Implementação disponível ('msm')

## Alguns pontos críticos

- Suposição de homogeneidade do processo

## Alguns pontos críticos

- Suposição de homogeneidade do processo
- Escolha de  $Pr(S_{i1})$

## Alguns pontos críticos

- Suposição de homogeneidade do processo
- Escolha de  $Pr(S_{i1})$
- **Custo computacional**

## Desenvolvimentos necessários

- Relaxar suposição de homogeneidade do processo



## Desenvolvimentos necessários

- Relaxar suposição de homogeneidade do processo
- Incluir vetor de efeitos aleatórios espaciais  $b_{rs}$  no modelo

$$q_{rs}\{t, x(t)\} = q_{rs}(t) \exp\{\beta'_{rs}x(t) + b'_{rs}u\}$$

(Nathoo & Chairmaine, 2006 (30))

## Desenvolvimentos necessários

- Relaxar suposição de homogeneidade do processo
- Incluir vetor de efeitos aleatórios espaciais  $b_{rs}$  no modelo

$$q_{rs}\{t, x(t)\} = q_{rs}(t) \exp\{\beta'_{rs}x(t) + b'_{rs}u\}$$

(Nathoo & Chairmaine, 2006 (30))

- **Incorporar modelos de função de transferência em variáveis ambientais**

## Desenvolvimentos necessários

- Relaxar suposição de homogeneidade do processo
- Incluir vetor de efeitos aleatórios espaciais  $b_{rs}$  no modelo

$$q_{rs}\{t, x(t)\} = q_{rs}(t) \exp\{\beta'_{rs}x(t) + b'_{rs}u\}$$

(Nathoo & Chairmaine, 2006 (30))

- Incorporar modelos de função de transferência em variáveis ambientais
- **Acomodar indivíduos resistentes à doença: Modelo mover-stayer**

# Verossimilhança (Nathoo & Chairmaine, 2006)

- Verossimilhança

$$L(X|\theta) = \prod_{(r,s) \in T} L_{rs}$$

$$L_{rs} = \left[ \prod_{i=1}^N \prod_{m=1}^{E_i} q_{irs}(T_{im})^{D_{irsm}} \right] \times \exp \left( - \sum_{i=1}^N \int_0^{C_i} R_{ir}(u) q_{irs}(u) du \right)$$

# Verossimilhança (Nathoo & Chairmaine, 2006)

- Verossimilhança

$$L(X|\theta) = \prod_{(r,s) \in T} L_{rs}$$

$$L_{rs} = \left[ \prod_{i=1}^N \prod_{m=1}^{E_i} q_{irs}(T_{im})^{D_{irsm}} \right] \times \exp \left( - \sum_{i=1}^N \int_0^{C_i} R_{ir}(u) q_{irs}(u) du \right)$$

- $E_i$  é o número de transições de estado para estado para indivíduo  $i$

# Verossimilhança (Nathoo & Chairmaine, 2006)

- Verossimilhança

$$L(X|\theta) = \prod_{(r,s) \in T} L_{rs}$$

$$L_{rs} = \left[ \prod_{i=1}^N \prod_{m=1}^{E_i} q_{irs}(T_{im})^{D_{irsm}} \right] \times \exp \left( - \sum_{i=1}^N \int_0^{C_i} R_{ir}(u) q_{irs}(u) du \right)$$

- $E_i$  é o número de transições de estado para estado para indivíduo  $i$
- $D_{irsm} = I\{S_{i(m-1)} = r, S_{im} = s\} (m = 1, \dots, E_i)$