

Statistické testování algoritmů

Radek Mařík

ČVUT FEL, K13132

December 18, 2014



Obsah

1 Klasické propagování kovarianční matic

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matic - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Obsah

1 Klasické propagování kovarianční matic

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matic - implicitní forma

- Definice
- Příklady
- Validace algoritmů


Zpracování textury



(a) Původní obraz



(b) Detekovaná skrvna




(c) Původní obraz



(d) Detekovaná prasklina



Model systému



Obsah

1 Klasické propagování kovarianční matic

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matic - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Propagace kovarianční matice

- vstupní data: \mathbf{X}
- výstupní data: \mathbf{Y}
- explicitní vztah: $\mathbf{Y} = \mathbf{F}(\mathbf{X})$

Propagace kovarianční matice:

$$\boldsymbol{\Sigma}_Y = \mathbf{J} \boldsymbol{\Sigma}_X \mathbf{J}^T$$

kde

- $\boldsymbol{\Sigma}_Y$... kovarianční matice výstupních dat \mathbf{Y} ,
- $\boldsymbol{\Sigma}_X$... kovarianční matice vstupních dat \mathbf{X} ,
- \mathbf{J} ... lineární operátor prvního řádu Taylorova rozvoje funkce $\mathbf{F}(\mathbf{X})$ v okolí bodu \mathbf{X}_0 .

Propagace kovariační matice - odvození

explicitní vztah:

$$\underline{\mathbf{Y} = \mathbf{F}(\mathbf{X})}$$

Taylorův rozvoj v okolí bodu \mathbf{X}_0 :

$$\mathbf{Y} = \mathbf{Y}_0 + \frac{\partial \mathbf{F}}{\partial \mathbf{X}} \Big|_{\mathbf{X}_0} (\mathbf{X} - \mathbf{X}_0) + \mathbf{R}_{\mathbf{Y}_0}$$

substituce:

$$\delta \mathbf{X} = \mathbf{X} - \mathbf{X}_0, \quad \delta \mathbf{Y} = \mathbf{Y} - \mathbf{Y}_0$$

$$\mathbf{J}_0 = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} \Big|_{\mathbf{X}_0} \dots \text{Jakobián}$$

$$\delta \mathbf{Y} = \mathbf{J}_0 \cdot \delta \mathbf{X} + \mathbf{R}_{\mathbf{Y}_0}$$

$$\delta \mathbf{Y} \cdot \delta \mathbf{Y}^T = (\mathbf{J}_0 \cdot \delta \mathbf{X} + \mathbf{R}_{\mathbf{Y}_0})(\mathbf{J}_0 \cdot \delta \mathbf{X} + \mathbf{R}_{\mathbf{Y}_0})^T = \mathbf{J}_0 \cdot \delta \mathbf{X} \cdot \delta \mathbf{X}^T \cdot \mathbf{J}_0^T + \mathbf{R}_{\mathbf{Y} \mathbf{Y}_0}$$

$$\underline{\Sigma_{\mathbf{Y} \mathbf{Y}_0}} = 1/n \sum_{i=1}^n (\delta \mathbf{Y}_i \cdot \delta \mathbf{Y}_i^T) = 1/n \sum_{i=1}^n (\mathbf{J}_0 \cdot \delta \mathbf{X}_i \cdot \delta \mathbf{X}_i^T \cdot \mathbf{J}_0^T) =$$

$$= \mathbf{J}_0 \cdot \underbrace{1/n \sum_{i=1}^n (\delta \mathbf{X}_i \cdot \delta \mathbf{X}_i^T)}_{\Sigma_{\mathbf{X} \mathbf{X}_0}} \cdot \mathbf{J}_0^T = \underline{\mathbf{J}_0 \cdot \Sigma_{\mathbf{X} \mathbf{X}_0} \cdot \mathbf{J}_0^T}$$



Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip


2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Model datového toku



Přímé propagování chyby

- Odpadá zdlouhavé odvození chybového modelu.
- **Substituce hodnot proměnných strukturami** modelu chyby.
- "Symbolická derivace" následovaná výpočtem.
- Bodová analýza.
- Výpočet okamžité chyby.
- Lze hodnotit přesnost výpočtu.
- Předpokládá dostupnost zdrojového kódu.
- Chybový model jakéhokoliv hodnoty proměnné je vypočten pomocí chybových modelů vstupních operandů operace.
- Parametry chybových modelů:
 - dáno,
 - určené přesností měření,
 - určené předchozími výpočty.

Přímé propagování chyby - implementace

- Založeno na přetížení operátorů v objektově-orientovaném kódování.
- Přepínání mezi normálním kódem a kódem propagující chyby.

C++ normální kód

```
typedef double Reالت;
```

C++ kód propagující chyby

```
class Reالت { . . . . . };
```

Příklad

```
Reالت x, a=3, b=5;  
x = a + b;
```

Přímé propagování chyby - implementace

- Založeno na přetížení operátorů v objektově-orientovaném kódování.
- Přepínání mezi normálním kódem a kódem propagující chyby.

C++ normální kód

```
typedef double Reالت;
```

C++ kód propagující chyby

```
class Reالت . . . . . ;
```

Příklad

```
Reالت x, a=3, b=5;  
x = a + b;
```

Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- **Variance**
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Propagace variance

Dána funkce $g(x, y)$ dvou proměnných x a y s variancemi σ_{xx}^2 a σ_{yy}^2 a kovariancí σ_{xy} .

Variance hustoty chyb hodnot funkce

$$\begin{aligned}\sigma_{gg}^2(x_0, y_0) = & \left. \sigma_{xx}^2 (\partial g / \partial x)^2 \right|_{(x_0, y_0)} \\ & + \left. \sigma_{yy}^2 (\partial g / \partial y)^2 \right|_{(x_0, y_0)} \\ & + 2 \left. \sigma_{xy} (\partial g / \partial x)(\partial g / \partial y) \right|_{(x_0, y_0)}\end{aligned}$$

Typické zjednodušení: $\sigma_{xy} = 0$

$$\sigma_{gg}^2(x_0, y_0) = \left. \sigma_{xx}^2 (\partial g / \partial x)^2 \right|_{(x_0, y_0)} + \left. \sigma_{yy}^2 (\partial g / \partial y)^2 \right|_{(x_0, y_0)}$$

Propagace variance

Dána funkce $g(x, y)$ dvou proměnných x a y s variancemi σ_{xx}^2 a σ_{yy}^2 a kovariancí σ_{xy} .

Variance hustoty chyb hodnot funkce

$$\begin{aligned}\sigma_{gg}^2(x_0, y_0) = & \left. \sigma_{xx}^2 (\partial g / \partial x)^2 \right|_{(x_0, y_0)} \\ & + \left. \sigma_{yy}^2 (\partial g / \partial y)^2 \right|_{(x_0, y_0)} \\ & + 2 \left. \sigma_{xy} (\partial g / \partial x) (\partial g / \partial y) \right|_{(x_0, y_0)}\end{aligned}$$

Typické zjednodušení: $\sigma_{xy} = 0$


$$\sigma_{gg}^2(x_0, y_0) = \left. \sigma_{xx}^2 (\partial g / \partial x)^2 \right|_{(x_0, y_0)} + \left. \sigma_{yy}^2 (\partial g / \partial y)^2 \right|_{(x_0, y_0)}$$

Propagace variance

Základní aritmetické operace a standardní funkce:

Funkce	Propagace variance
$z = x + y$	$\sigma_{zz}^2 = \sigma_{xx}^2 + \sigma_{yy}^2$
$z = x - y$	$\sigma_{zz}^2 = \sigma_{xx}^2 + \sigma_{yy}^2$
$z = xy$	$\sigma_{zz}^2 = y_0^2 \sigma_{xx}^2 + x_0^2 \sigma_{yy}^2$
$z = x/y$	$\sigma_{zz}^2 = (\sigma_{xx}^2 + x_0^2/y_0^2 \sigma_{yy}^2)/y_0^2$
$z = x^2$	$\sigma_{zz}^2 = 4x_0^2 \sigma_{xx}^2$
$z = \sqrt{x}$	$\sigma_{zz}^2 = \frac{1}{4x_0} \sigma_{xx}^2$
$z = \sin x$	$\sigma_{zz}^2 = \cos^2 x_0 \sigma_{xx}^2$
$z = \cos x$	$\sigma_{zz}^2 = \sin^2 x_0 \sigma_{xx}^2$
$z = e^x$	$\sigma_{zz}^2 = e^{2x_0} \sigma_{xx}^2$
$z = \ln x$	$\sigma_{zz}^2 = 1/x_0^2 \sigma_{xx}^2$
$z = \log_a x$	$\sigma_{zz}^2 = \frac{1}{(x_0 \ln a)^2} \sigma_{xx}^2$
$z = x^y$	$(y_0^2/x_0^2 \sigma_{xx}^2 + \ln^2 x_0 \sigma_{yy}^2) x_0^{2y_0}$

Propagace variance - příklad



Hodnoty funkce $\sin x$ pro argument s absolutní chybou ± 0.25 .

Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Propagace chyby Min/Max

Uzavřený interval reálných čísel nebo Interval

$$\begin{aligned} A &= [a_{\min}, a_{\max}] \\ &= \{t \mid a_{\min} \leq t \leq a_{\max}, a_{\min}, a_{\max} \in \mathcal{R}\} \end{aligned}$$

- $I(\mathcal{R})$... množina uzavřených intervalů,
- A, B, C, \dots, X, Y, Z ... intervaly z $I(\mathcal{R})$.

Nechť $* \in \{+, -, \cdot, :\}$ je binární operace na množině reálných čísel \mathcal{R} .
Jestliže $A, B \in I(\mathcal{R})$, potom

$$A * B = \{z = a * b \mid a \in A, b \in B\}$$

definuje binární operace na $I(\mathcal{R})$.

Propagace chyby Min/Max - operace

Vstupní hodnoty:

$$x \in [x_{min}, x_{max}], y \in [y_{min}, y_{max}]$$

Funkce	Výstupní Min/Max intervaly
$z = x + y$	$[x_{min} + y_{min}, x_{max} + y_{max}]$
$z = x - y$	$[x_{min} - y_{max}, x_{max} - y_{min}]$
$z = x \cdot y$	$[\min\{x_{min} \cdot y_{min}, x_{min} \cdot y_{max}, x_{max} \cdot y_{min}, x_{max} \cdot y_{max}\}, \max\{x_{min} \cdot y_{min}, x_{min} \cdot y_{max}, x_{max} \cdot y_{min}, x_{max} \cdot y_{max}\}]$
$z = x/y$	$[x_{min}, x_{max}] \cdot [1/y_{max}, 1/y_{min}]$

Jestliže $g(x)$ je spojitá unární operace na \mathcal{R} , potom

$$g(X) = [\min_{x \in X} g(x), \max_{x \in X} g(x)]$$

definuje *unarní operaci* na $I(\mathcal{R})$.

Propagace chyby Min/Max - monotónní unární funkce

- rostoucí funkce $g_i(x)$:


$$[x_{min}, x_{max}] \implies [g_i(x_{min}), g_i(x_{max})]$$

- klesající funkce $g_d(x)$:

$$[x_{min}, x_{max}] \implies [g_d(x_{max}), g_d(x_{min})]$$

Propagace chyby Min/Max - nemonotónní funkce

$\sin x$ s 10% relativní chybou argumentu



Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- **Příklad**

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Jednoduchý příklad

Funkce

$$f(x) = x + 10$$

Její implementace:

$$f_{imp}(x) = (x \cdot x - 100)/(x - 10).$$

Testován rozsah x : $[0, 20]$ s krokem 0.01.

Jednoduchý příklad - C++ kód


```
#include <iostream.h>
#include "StdType.hh"
int main(void)
{
    for (RealT x=0; x<=20; x+=0.01){
        if (x == 10) continue; // to avoid division by zero
        cout << x << ' ' << (x*x -100)/(x-10) << '\n';
    }
    return 0;
}
```

StdType.hh:

- `typedef double RealT;`
- `class RealT { };`


Jednoduchý příklad - výsledek

Relativní chyba 10% ve vstupních datech.




Detekce prasklin [SPK95]


Textura žuly s horizontální prasklinou.



Výpočet DFT vzhledem k definici




(a) 0.1% výpočetní chyba




(b) přesnost procesoru - double



Výpočet DFT podle modifikace (modulo)



(a) 0.1% výpočetní chyba



(b) přesnost procesoru - double

Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Propagace kovarianční matice - implicitní forma [Har94]

- vstupní data: \mathbf{X}
- výstupní data: \mathbf{Y}
- vztah mezi \mathbf{Y} a \mathbf{X} je vyjádřen implicitní skalární funkcí $F(\mathbf{X}, \mathbf{Y})$.

Definice úlohy: dáno $\hat{\mathbf{X}} = \mathbf{X}_0 + \Delta\mathbf{X}$, určit $\hat{\mathbf{Y}} = \mathbf{Y}_0 + \Delta\mathbf{Y}$ tak, aby se minimalizovala $F(\hat{\mathbf{X}}, \hat{\mathbf{Y}})$ za předpokladu, že \mathbf{Y}_0 minimalizuje $F(\mathbf{X}_0, \mathbf{Y}_0)$.
Estimátor:

$$\hat{\Sigma}_{\Delta\mathbf{Y}} = \left(\frac{\partial \mathbf{g}}{\partial \mathbf{Y}}(\hat{\mathbf{X}}, \hat{\mathbf{Y}}) \right)^{-1} \frac{\partial \mathbf{g}}{\partial \mathbf{X}}(\hat{\mathbf{X}}, \hat{\mathbf{Y}}) \Sigma_{\Delta\mathbf{X}} \frac{\partial \mathbf{g}}{\partial \mathbf{X}}(\hat{\mathbf{X}}, \hat{\mathbf{Y}})^T \left[\left(\frac{\partial \mathbf{g}}{\partial \mathbf{Y}}(\hat{\mathbf{X}}, \hat{\mathbf{Y}}) \right)^T \right]^{-1}$$

kde

$$\mathbf{g}(\mathbf{X}_0, \mathbf{Y}_0) = \frac{\partial F}{\partial \mathbf{Y}}(\mathbf{X}_0, \mathbf{Y}_0)$$

Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- **Příklady**
- Validace algoritmů

Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \rightsquigarrow y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x||\sigma_x^2||2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2||-4x||\sigma_x^2||-4x||1/2| = |4x^2\sigma_x^2|$$

Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x| |\sigma_x^2| |2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2| |-4x| |\sigma_x^2| |-4x| |1/2| = |4x^2\sigma_x^2|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = \left| \sigma_y^2 \right| = \left| 2x \right| \left| \sigma_x^2 \right| \left| 2x \right| = \left| 4x^2 \sigma_x^2 \right|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = \left| \sigma_y^2 \right| = \left| 1/2 \right| \left| -4x \right| \left| \sigma_x^2 \right| \left| -4x \right| \left| 1/2 \right| = \left| 4x^2 \sigma_x^2 \right|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x||\sigma_x^2||2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2||-4x||\sigma_x^2||-4x||1/2| = |4x^2\sigma_x^2|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x| |\sigma_x^2| |2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2| |-4x| |\sigma_x^2| |-4x| |1/2| = |4x^2\sigma_x^2|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \rightsquigarrow y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x| |\sigma_x^2| |2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2| |-4x| |\sigma_x^2| |-4x| |1/2| = |4x^2\sigma_x^2|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = | \sigma_y^2 | = | 2x || \sigma_x^2 | | 2x | = | 4x^2 \sigma_x^2 |$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = | \sigma_y^2 | = | 1/2 | | -4x | | \sigma_x^2 | | -4x | | 1/2 | = | 4x^2 \sigma_x^2 |$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = | \sigma_y^2 | = | 2x || \sigma_x^2 | | 2x | = | 4x^2 \sigma_x^2 |$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = | \sigma_y^2 | = | 1/2 | | -4x | | \sigma_x^2 | | -4x | | 1/2 | = | 4x^2 \sigma_x^2 |$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\Sigma_{y^2} = |\sigma_y^2| = |2x| |\sigma_x^2| |2x| = |4x^2\sigma_x^2|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\Sigma_{yy} = |\sigma_y^2| = |1/2| |-4x| |\sigma_x^2| |-4x| |1/2| = |4x^2\sigma_x^2|$$



Jednoduchý příklad $y = x^2$

Explicitní propagace

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}) \quad \rightsquigarrow \quad y = x^2$$

$$J = \frac{\partial \mathbf{F}}{\partial \mathbf{X}} = 2x$$

$$\boldsymbol{\Sigma}_{y^2} = \left| \sigma_y^2 \right| = \left| 2x \right| \left| \sigma_x^2 \right| \left| 2x \right| = \left| 4x^2 \sigma_x^2 \right|$$

Implicitní propagace

$$F(\mathbf{X}, \mathbf{Y}) \quad \rightsquigarrow \quad F(x; y) = (y - x^2)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \frac{\partial F}{\partial y} = 2(y - x^2)$$

$$\frac{\partial g}{\partial y} = 2 \quad \frac{\partial g}{\partial x} = -4x$$

$$\boldsymbol{\Sigma}_{yy} = \left| \sigma_y^2 \right| = \left| 1/2 \right| \left| -4x \right| \left| \sigma_x^2 \right| \left| -4x \right| \left| 1/2 \right| = \left| 4x^2 \sigma_x^2 \right|$$



Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy} & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy} & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy} & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy} & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy}, & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy}, & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \begin{vmatrix} -1 \\ 1 \end{vmatrix} = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Explicitní propagace: $q = y - x$

$$\begin{aligned}
 \mathbf{J} &= \begin{vmatrix} \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} -1 & 1 \end{vmatrix} \\
 \boldsymbol{\Sigma}_{qq} &= \left| \sigma_q^2 \right| = \\
 &= \left| \begin{matrix} -1 & 1 \end{matrix} \right| \left| \begin{matrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{matrix} \right| \left| \begin{matrix} -1 \\ 1 \end{matrix} \right| = \\
 &= \left| \begin{matrix} -\sigma_x^2 + \sigma_{xy}, & -\sigma_{xy} + \sigma_y^2 \end{matrix} \right| \left| \begin{matrix} -1 \\ 1 \end{matrix} \right| = \\
 &= \left| \begin{matrix} +\sigma_x^2 - \sigma_{xy} - \sigma_{xy} + \sigma_y^2 \end{matrix} \right| = \\
 &= \left| \begin{matrix} \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \end{matrix} \right|
 \end{aligned}$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$
 $F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots$ minimalizace pro 1 bod

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| -1 \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$
 $F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots$ minimalizace pro 1 bod

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| -1 \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| -1 \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| \begin{matrix} 1 \\ -1 \end{matrix} \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| \begin{matrix} 1 \\ -1 \end{matrix} \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \begin{vmatrix} 1 \\ -1 \end{vmatrix} =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| -1 \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Jednoduchý příklad $y = x + q$ Implicitní propagace: $y = x + q$

$$F(\mathbf{X}, \mathbf{Y}) \rightsquigarrow F(x, y; q) = (y - x - q)^2 \cdots \text{minimalizace pro 1 bod}$$

$$g = \partial F / \partial q = -2(y - x - q)$$

$$\partial g / \partial q = 2 \quad \partial g / \partial x = 2 \quad \partial g / \partial y = -2$$

$$\Sigma_{qq} = \left| \sigma_q^2 \right| = \left| 2 \right|^{-1} \left| 2, -2 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| 2 \right|^{-1} =$$

$$= \left| 1, -1 \right| \begin{vmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{vmatrix} \left| -1 \right| =$$

$$= \left| \sigma_x^2 - \sigma_{xy} \quad \sigma_{xy} - \sigma_y^2 \right| \left| -1 \right| =$$

$$= \left| \sigma_x^2 - 2\sigma_{xy} + \sigma_y^2 \right|$$

Obsah

1 Klasické propagování kovarianční matice

- Motivace
- Princip

2 Přímé propagování chyby

- Princip
- Variance
- Min/Max chyba
- Příklad

3 Propagace kovarianční matice - implicitní forma

- Definice
- Příklady
- Validace algoritmů

Statistická validace algoritmu 1 [Har94]

- Testuje se, zda vypočtené odhady patří do distribuce s danou střední hodnotou a kovarianční maticí.
- Hladina významnosti α .
- Testovaná statistika $\hat{\phi}$.
- Hodnota ϕ_0 zamítnutí hypotézy.
- Postup:
 - ① určí správnou odpověď pro ideální případ bez šumu,
 - ② pertubuj vstupní data normálním rozložením se nulou střední hodnotou a danou kovarianční maticí,
 - ③ propaguj analyticky odhady kovarianční matici.

Statistická validace algoritmu 2 [Har94]

- Testovaná hypotéza: zda pozorování $\theta_1, \dots, \theta_N$ pochází z normálního rozložení se střední hodnotou $\bar{\theta}$ a kovarianční maticí Σ .
- Existuje uniformně nejsilnější test

$$B = \sum_{n=1}^N (\theta_n - \bar{\theta})(\theta_n - \bar{\theta})^T$$

Definujme

$$\lambda = (e/N)^{pN/2} |B\Sigma^1|^{N/2} \times \exp\left(-\frac{1}{2} [tr(B\Sigma_1) + N(\bar{\theta} - \theta)^T \Sigma^1 (\bar{\theta} - \theta)]\right)$$

- Testovaná statistika:

$$T = -2 \log \lambda$$

- T distribuováno podle $\chi^2_{p(p+1)/2+p}$ kde p je dimenze θ
- T_α : $Prob(\chi^2_{p(p+1)/2+p} \geq T_\alpha) = \alpha$

Literatura I



R.M. Haralick.

Propagating covariance in computer vision.

In *12th International Conference on Pattern Recognition (Jerusalem, Israel, 1994)*, volume I, pages 493–498, Washington, DC, 1994. IEEE Computer Society Press.



K. Y. Song, M. Petrou, and J. Kittler.

Texture crack detection.

Machine Vision and Application, 8:63–76, 1995.