



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání

MŠMT
MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

CENTRUM LETECKÉHO A KOSMICKÉHO VÝZKUMU

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE
FAKULTA STROJNÍ
Projekt CZ.02.1.01/0.0/0.0/16_019/0000826

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů

Analýza slabých signálů


Analýza slabých signálů

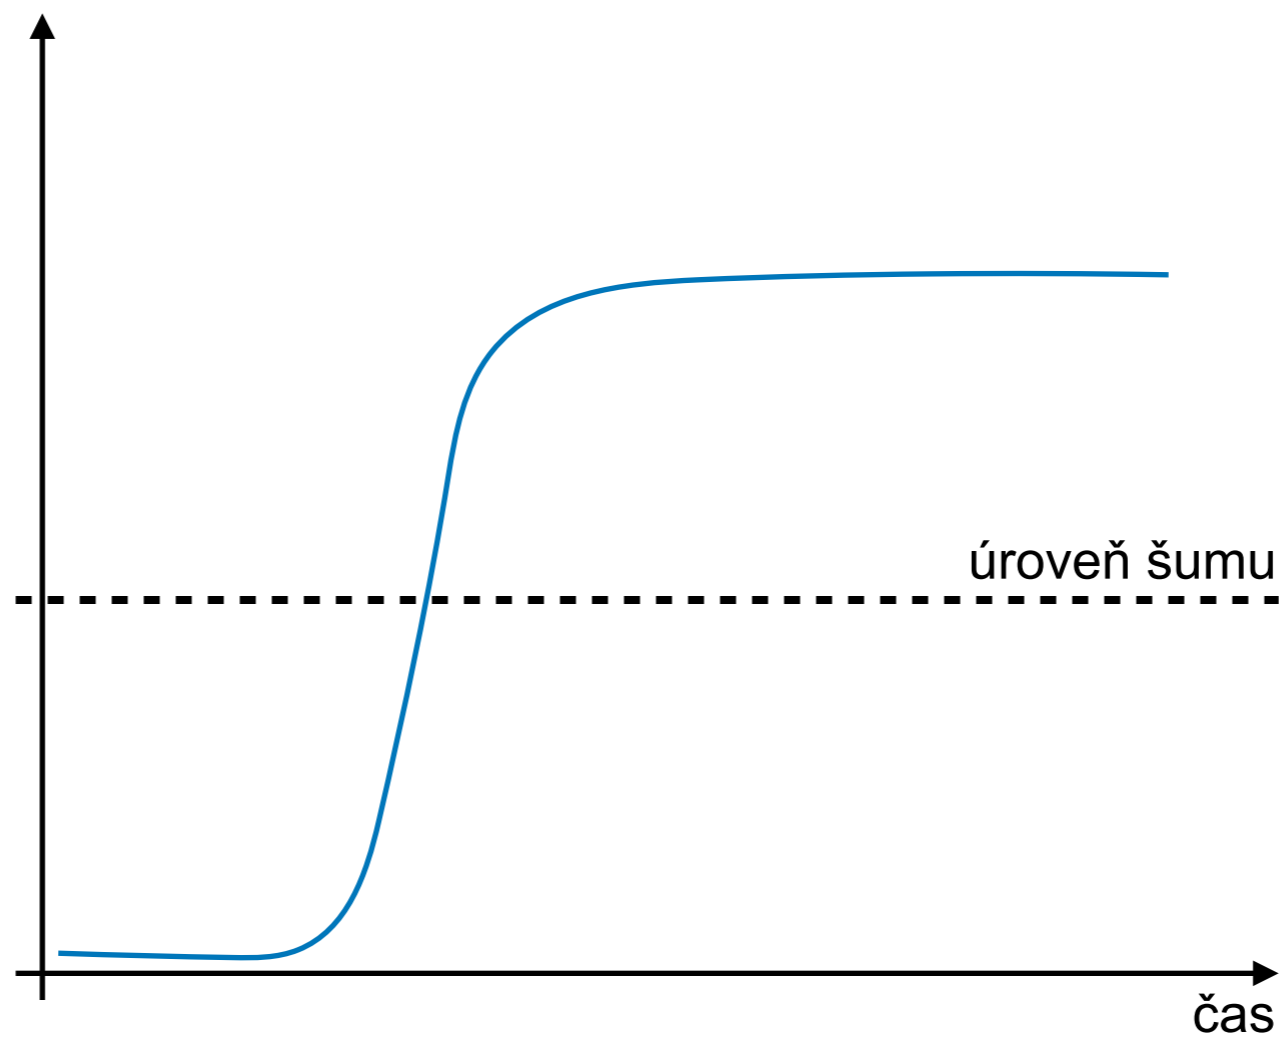
Analýza slabých signálů

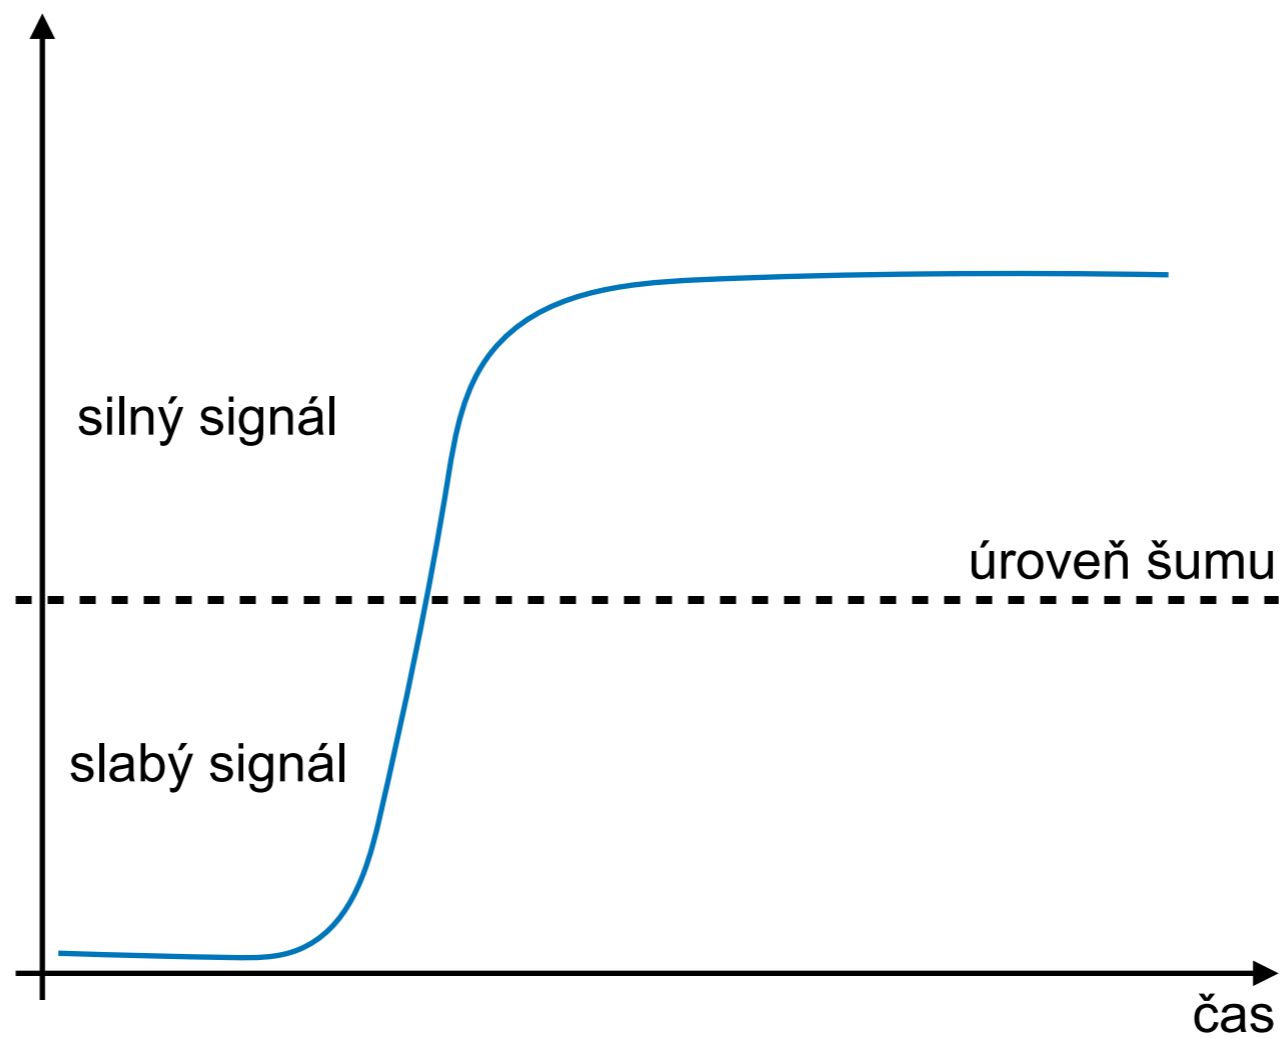
Analýza slabých signálů

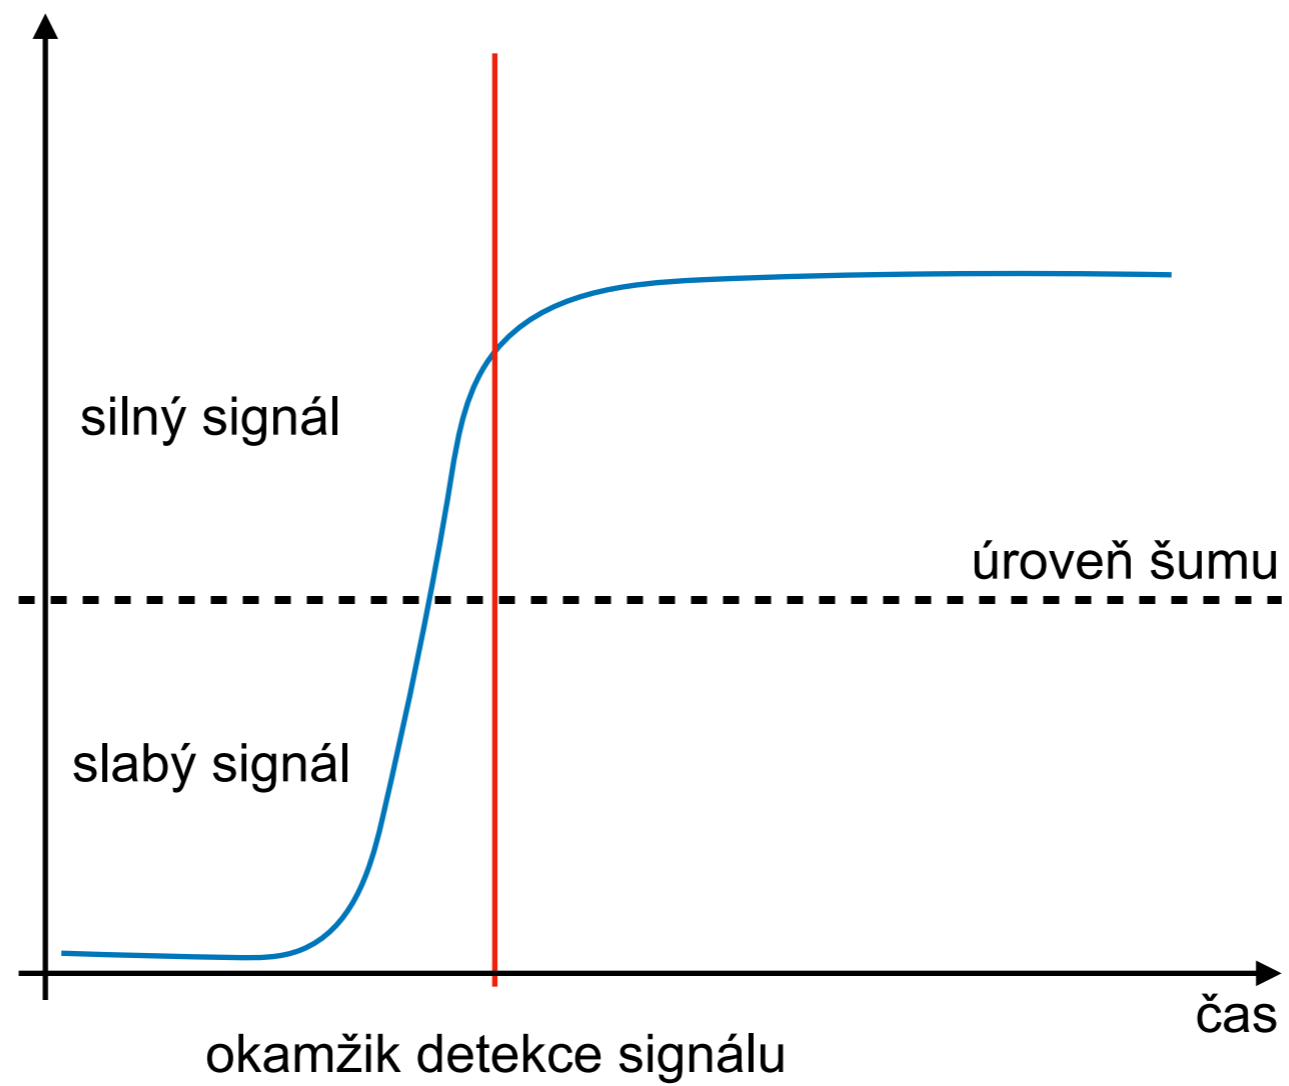
Analýza slabých signálů











- 1. Rozhodování za podmínek neurčitosti**
- 2. Analýza (elektrických) signálů**
- 3. Statistické monitorování procesů (SPC)**


1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.


“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)



1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)




- manažerské rozhodování (rozpoznávání jazyka, strategické plánování, politika, ...)

1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)




- manažerské rozhodování (rozpoznávání jazyka, strategické plánování, politika, ...)
- finanční služby (pojišťovnictví, banky, leasingové společnosti, ...)

1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)




- manažerské rozhodování (rozpoznávání jazyka, strategické plánování, politika, ...)
- finanční služby (pojišťovnictví, banky, leasingové společnosti, ...)
- bezpečnost, obrana (analýza komunikačních sítí, sociální sítě, internet, mobilní sítě,)

1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)




- manažerské rozhodování (rozpoznávání jazyka, strategické plánování, politika, ...)
- finanční služby (pojišťovnictví, banky, leasingové společnosti, ...)
- bezpečnost, obrana (analýza komunikačních sítí, sociální sítě, internet, mobilní sítě,)

klasifikace, logistická regrese, strojové učení, ...

1. Rozhodování v oblasti společenských aplikací

Slabé signály jsou nejasné a nepřesné indicie předcházející důležité události, zatímco **silné signály** jsou dostatečně viditelné a konkrétní.

(“Weak signals” are “imprecise early indications about impending impactful events”, while strong signals are “sufficiently visible” and “concrete”. Ansoff, H.I., McDonnell, E.J.: *Implanting strategic management*, Prentice Hall, 1990)




- manažerské rozhodování (rozpoznávání jazyka, strategické plánování, politika, ...)
- finanční služby (pojišťovnictví, banky, leasingové společnosti, ...)
- bezpečnost, obrana (analýza komunikačních sítí, sociální sítě, internet, mobilní sítě,)

klasifikace, logistická regrese, strojové učení, ...

Cooper, A., Voigt, Ch., Unterfrauner, E., Kravcik, M., Pawlowski, J., Pirkkalainen, H. (2011): Report on Weak Signals Collection. TEL-Map report.

Hiltunen, E. (2008). Good Sources of Weak Signals: A Global Study of Where Futurists Look For Weak Signals. *Journal of Futures Studies*, 12(4).

Humbert Lesca, Nicolas Lesca, E.: *Strategic Decisions and Weak Signals: Anticipation for Decision-Making*. Wiley&sons, 2014.



1. Detekce založená na klasifikaci

V souvislosti s prudkým šířením sociálních sítí je vytvářeno obrovské množství dat. Extrakce informací o zajímavých událostech z tohoto rozsáhlého datového fondu se stalo zajímavým ale i žádaným směrem výzkumu. Jedním z významných směrů v této oblasti je detekce signálů indikujících vznik cílové události. To lze zložit například na získávání informací z cíleného textu. Běžné zjišťování existence cílové události je založeno na dostatečném množství zpráv pro její detekci. To vede k tomu, že jsou detekovány pouze významné události se silnými signály. Čekání na akumulaci signálů, aby se mohly stát silnými signály, může způsobit zpožděné zjištění události. Cílem detekce slabých signálů je rozpoznat vznik cílové události na základě tzv. „slabých signálů“ reprezentovaných relativně malým množstvím zpráv.

1. Detekce založená na klasifikaci

V souvislosti s prudkým šířením sociálních sítí je vytvářeno obrovské množství dat. Extrakce informací o zajímavých událostech z tohoto rozsáhlého datového fondu se stalo zajímavým ale i žádaným směrem výzkumu. Jedním z významných směrů v této oblasti je detekce signálů indikujících vznik cílové události. To lze zložit například na získávání informací z cíleného textu. Běžné zjišťování existence cílové události je založeno na dostatečném množství zpráv pro její detekci. To vede k tomu, že jsou detekovány pouze významné události se silnými signály. Čekání na akumulaci signálů, aby se mohly stát silnými signály, může způsobit zpožděné zjištění události. Cílem detekce slabých signálů je rozpoznat vznik cílové události na základě tzv. „slabých signálů“ reprezentovaných relativně malým množstvím zpráv.

(Bihao Song: [Weak Signal Detection on Twitter Datasets](#). Thesis, TU Delft, 2012)

1. Detekce založená na klasifikaci

V souvislosti s prudkým šířením sociálních sítí je vytvářeno obrovské množství dat. Extrakce informací o zajímavých událostech z tohoto rozsáhlého datového fondu se stalo zajímavým ale i žádaným směrem výzkumu. Jedním z významných směrů v této oblasti je detekce signálů indikujících vznik cílové události. To lze zložit například na získávání informací z cíleného textu. Běžné zjišťování existence cílové události je založeno na dostatečném množství zpráv pro její detekci. To vede k tomu, že jsou detekovány pouze významné události se silnými signály. Čekání na akumulaci signálů, aby se mohly stát silnými signály, může způsobit zpožděné zjištění události. Cílem detekce slabých signálů je rozpoznat vznik cílové události na základě tzv. „slabých signálů“ reprezentovaných relativně malým množstvím zpráv.

(Bihao Song: [Weak Signal Detection on Twitter Datasets. Thesis, TU Delft, 2012](#))

Zpracování přirozeného jazyka (NLP) je oblast výzkumu, která pomocí počítače umožňuje zpracovat a pochopit přirozený jazyk ve formě textu nebo řeči. NLP je založeno na mnoha různých oborech, jako jsou počítačové vědy, lingvistika, matematika, elektrotechnika, psychologie. Aplikace NLP mají tři hlavní směry: rozpoznávání řeči, porozumění jazykům a generování jazyků.

Několikastupňová analýza: v prvním stupni jednoduchý filtr omezí množinu zpráv na ty, které obsahují „klíčová slova“

Následně pokročilé filtry využívající zpravidla metody umělé inteligence (logistickou regresi, klasifikaci, strojové učení) kvantifikují, třídí a hledají závislosti.

2. Analýza (elektrických) signálů

2. Analýza (elektrických) signálů

Při monitorování stavu zařízení je **slabý signál** typ signálu, který má velmi nízký poměr signálu k šumu (SNR). Proto je nutné vyvinout efektivní metody, které by zlepšily nebo získávaly užitečné informace z „hlučného“ signálu. Tyto metody mají za cíl vyřešit problém odhlučnění a oddělení smíšeného signálu.

2. Analýza (elektrických) signálů

Při monitorování stavu zařízení je **slabý signál** typ signálu, který má velmi nízký poměr signálu k šumu (SNR). Proto je nutné vyvinout efektivní metody, které by zlepšily nebo získávaly užitečné informace z „hlučného“ signálu. Tyto metody mají za cíl vyřešit problém odhlučnění a oddělení smíšeného signálu.

(Wang,J., Yang,L., Gao,L. : „Current progress on weak signal detection”. In Proceedings of the International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, Sichuan, 2013, China)

2. Analýza (elektrických) signálů

Při monitorování stavu zařízení je **slabý signál** typ signálu, který má velmi nízký poměr signálu k šumu (SNR). Proto je nutné vyvinout efektivní metody, které by zlepšily nebo získávaly užitečné informace z „hlučného“ signálu. Tyto metody mají za cíl vyřešit problém odhlučnění a oddělení smíšeného signálu.

(Wang,J., Yang,L., Gao,L. : „Current progress on weak signal detection”. In Proceedings of the International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, Sichuan, 2013, China)

2.1. Metody zložené na Duffingově oscilátoru

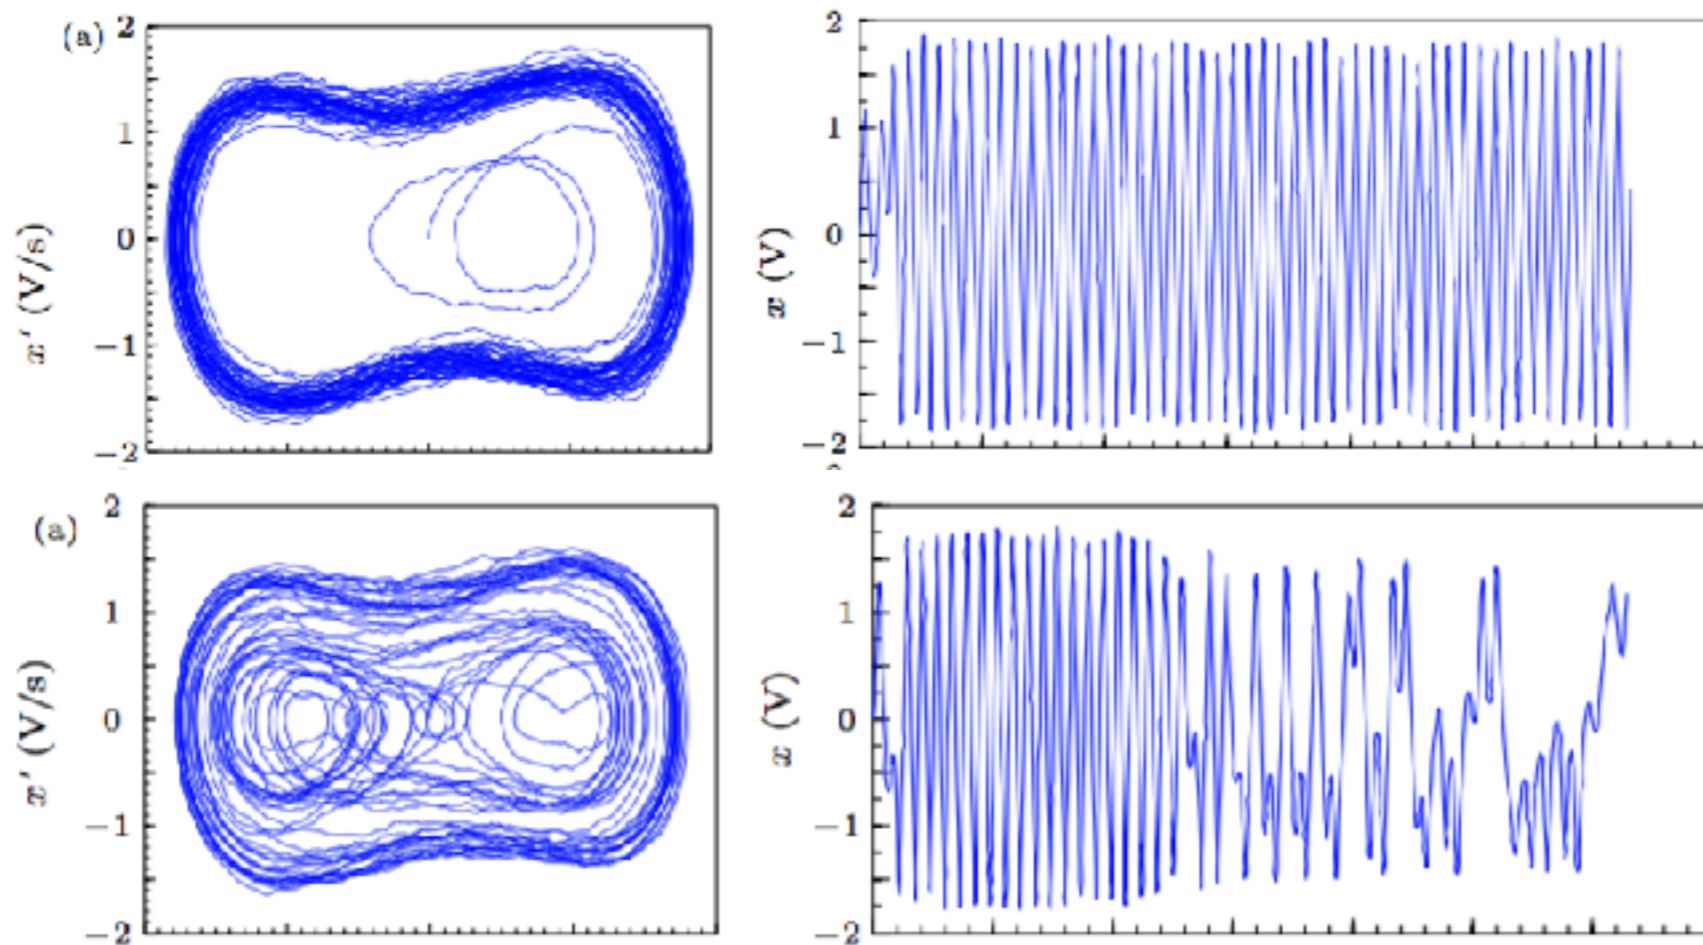
2.2. Princip stochastické rezonance (SR)

2.3. Metody počítačové inteligence (CI)

2.1. Metody detekce založené na Duffingově oscilátoru

Systemy deterministického chaosu jsou široce používány v řízení, synchronizaci a komunikaci. Jejich citlivost na počáteční hodnotu lze využít při detekci slabých signálů. Signál vstupující do citlivého chaotického systému způsobí zásadní změnu v jeho dynamickém chování. Proto lze na základě této charakteristiky odhadnout parametry slabého signálu pod dodatečným šumem pozadí s nulovou střední hodnotou. Při změně signálu systém přejde z periodického do chaotického stavu.


Duffing v roce 1914 sestrojil oscilátor, který generuje kmity, jejichž fázový diagram má dvě rovnovážné polohy, mezi nimiž tyto kmity „přeskakují“ díky malým změnám parametrů.




2.1. Metody detekce založené na Duffingově oscilátoru

Systemy deterministického chaosu jsou široce používány v řízení, synchronizaci a komunikaci. Jejich citlivost na počáteční hodnotu lze využít při detekci slabých signálů. Signál vstupující do citlivého chaotického systému způsobí zásadní změnu v jeho dynamickém chování. Proto lze na základě této charakteristiky odhadnout parametry slabého signálu pod dodatečným šumem pozadí s nulovou střední hodnotou. Při změně signálu systém přejde z periodického do chaotického stavu.

Duffing v roce 1914 sestrojil oscilátor, který generuje kmity, jejichž fázový diagram má dvě rovnovážné polohy, mezi nimiž tyto kmity „přeskakují“ díky malým změnám parametrů.



(Shi, S., Yuan, Y., Wang, H., Luo M.: Weak Signal Frequency Detection Method Based on Generalized Duffing Oscillator. Chinese Phys. Lett., 28(4) 2011)



2.2. Princip stochastické rezonance (SR)

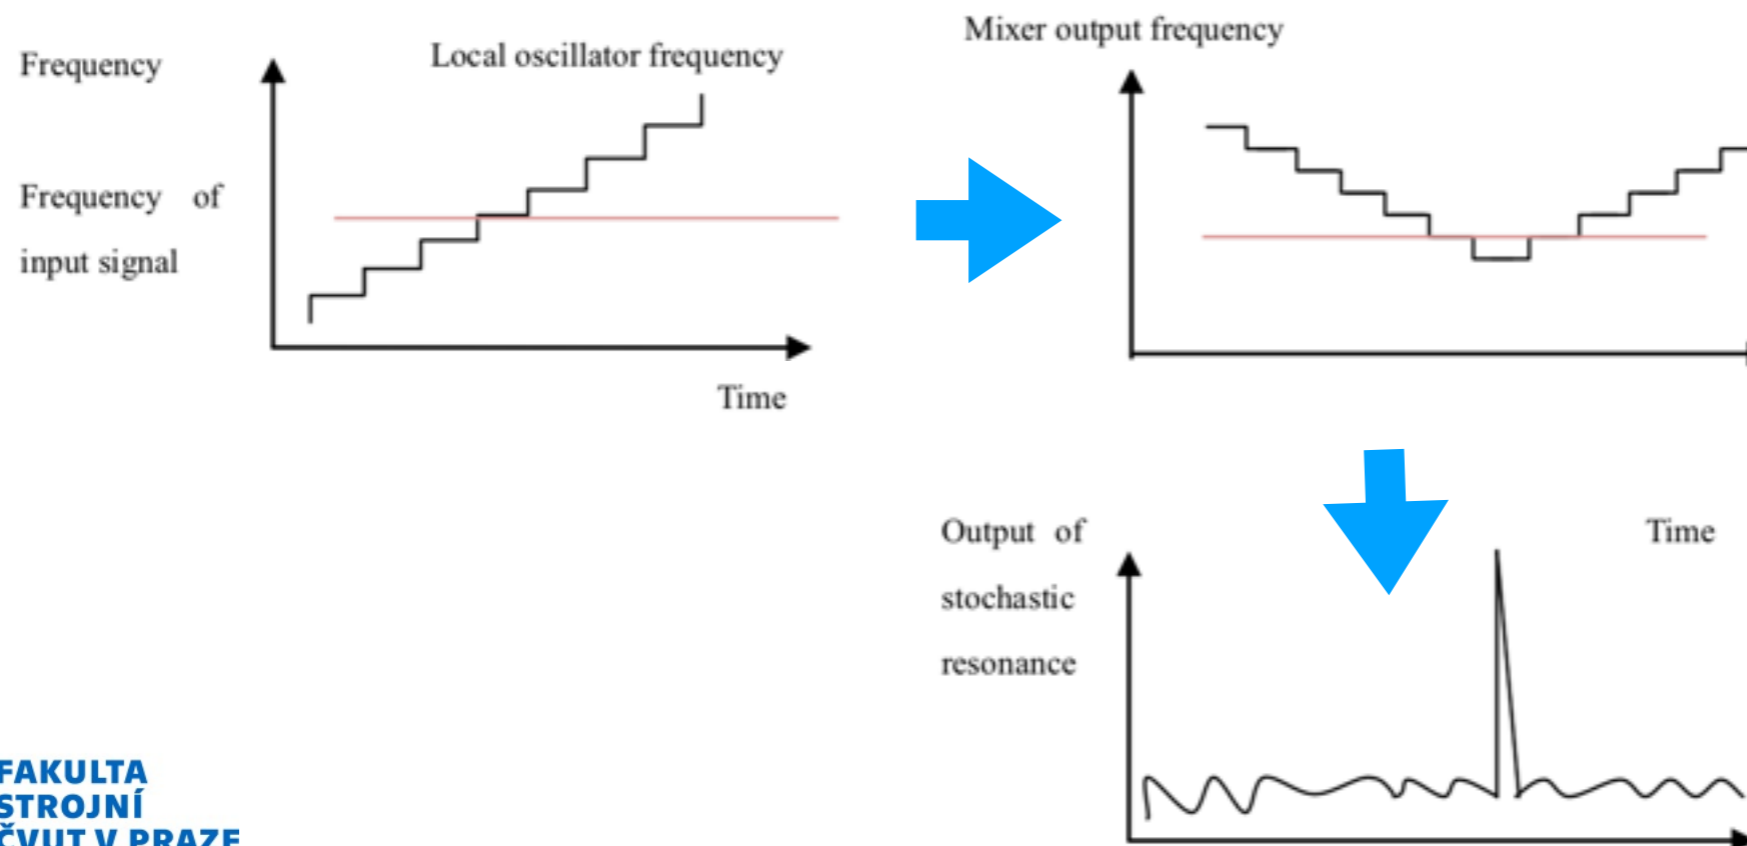
Koncept SR pochází od fyziků Roberta Benzi (ital), Alfonse Sutery (američan) a Angela Vulpoiani (ital), kteří jej použili při studiu starověkých meteorologických ledovců v roce 1981

SR je detekční metoda zaměřená na detekci neznámého slabého signálu založená na schopnosti stochastické rezonance detekovat silné nízkofrekvenční slabé signály. Smícháním neznámého signálu s plynulým lineárně se měnícím signálem lokálního oscilátoru je generován signál rozdílové frekvence, který je analyzován ve stochastickém rezonančním (SR) systému. Vzhledem k tomu, že SR systém je extrémně citlivý na nízkou frekvenci, maximální hodnota výstupu SR systému bude dosažena v případě, že frekvence lokálního oscilátoru a neznámého signálu si budou nejbližší. Frekvence neznámého signálu je přesně měřena z kmitočtu lokálního oscilátoru a frekvence rozdílového signálu.

2.2. Princip stochastické rezonance (SR)

Koncept SR pochází od fyziků Roberta Benzi (ital), Alfonse Sutery (američan) a Angela Vulpoiani (ital), kteří jej použili při studiu starověkých meteorologických ledovců v roce 1981


SR je detekční metoda zaměřená na detekci neznámého slabého signálu založená na schopnosti stochastické rezonance detekovat silné nízkofrekvenční slabé signály. Smícháním neznámého signálu s plynulým lineárně se měnícím signálem lokálního oscilátoru je generován signál rozdílové frekvence, který je analyzován ve stochastickém rezonančním (SR) systému. Vzhledem k tomu, že SR systém je extrémně citlivý na nízkou frekvenci, maximální hodnota výstupu SR systému bude dosažena v případě, že frekvence lokálního oscilátoru a neznámého signálu si budou nejbližší. Frekvence neznámého signálu je přesně měřena z kmitočtu lokálního oscilátoru a frekvence rozdílového signálu.



2.2. Princip stochastické rezonance (SR)

Koncept SR pochází od fyziků Roberta Benzi (ital), Alfonse Sutery (američan) a Angela Vulpoiani (ital), kteří jej použili při studiu starověkých meteorologických ledovců v roce 1981

SR je detekční metoda zaměřená na detekci neznámého slabého signálu založená na schopnosti stochastické rezonance detekovat silné nízkofrekvenční slabé signály. Smícháním neznámého signálu s plynulým lineárně se měnícím signálem lokálního oscilátoru je generován signál rozdílové frekvence, který je analyzován ve stochastickém rezonančním (SR) systému. Vzhledem k tomu, že SR systém je extrémně citlivý na nízkou frekvenci, maximální hodnota výstupu SR systému bude dosažena v případě, že frekvence lokálního oscilátoru a neznámého signálu si budou nejbližší. Frekvence neznámého signálu je přesně měřena z kmitočtu lokálního oscilátoru a frekvence rozdílového signálu.



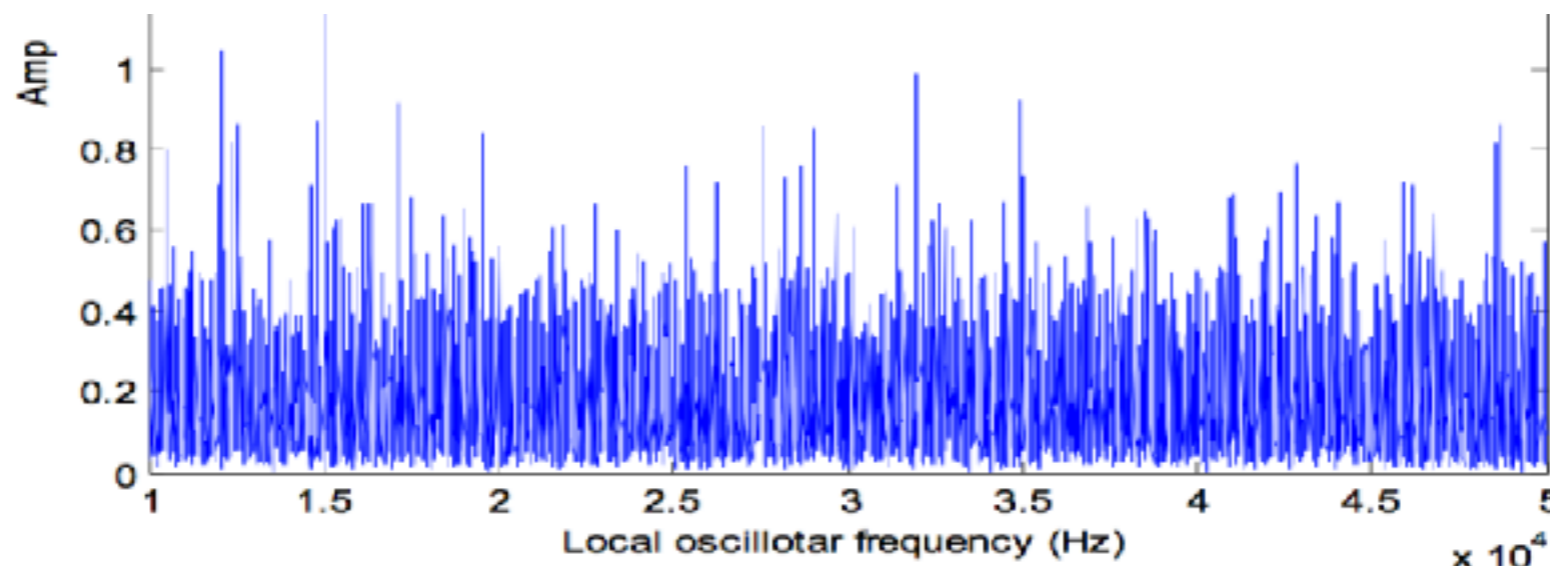
2.2. Princip stochastické rezonance (SR)

Koncept SR pochází od fyziků Roberta Benzi (ital), Alfonse Sutery (američan) a Angela Vulpoiani (ital), kteří jej použili při studiu starověkých meteorologických ledovců v roce 1981

SR je detekční metoda zaměřená na detekci neznámého slabého signálu založená na schopnosti stochastické rezonance detekovat silné nízkofrekvenční slabé signály. Smícháním neznámého signálu s plynulým lineárně se měnícím signálem lokálního oscilátoru je generován signál rozdílové frekvence, který je analyzován ve stochastickém rezonančním (SR) systému. Vzhledem k tomu, že SR systém je extrémně citlivý na nízkou frekvenci, maximální hodnota výstupu SR systému bude dosažena v případě, že frekvence lokálního oscilátoru a neznámého signálu si budou nejbližší. Frekvence neznámého signálu je přesně měřena z kmitočtu lokálního oscilátoru a frekvence rozdílového signálu.



(Shi, S., Yin, W., Yang, M., He M.: A High-Resolution Weak Signal Detection Method Based on Stochastic Resonance and Superhet Technology. In Proceedings of the 7th International ICST Conference on Communications and Networking, 2012, China)



2.3. Metody počítačové inteligence (CI)


Využití neuronových sítí - Learning Entropy

Learning Entropy - metoda detekce změny v chování sledovaného procesu, založená na detekci neobvyklého úsilí inkrementálně se učícího systému (neuronové sítě). Pokud se vstupní proces chová podle předem naučeného schématu z tréninkového úseku (kdy byl tzv. „pod statistickou kontrolou“), jeho váhy se s novým vstupem signálu mění jen nevýrazně. Jakmile však dojde ke změně, váhy jednotlivých neuronů se začnou rychle měnit. To způsobuje změnu entropie, kterou lze následně detekovat jako příznak změny chování celého procesu.

2.3. Metody počítačové inteligence (CI)

Využití neuronových sítí - Learning Entropy


Learning Entropy - metoda detekce změny v chování sledovaného procesu, založená na detekci neobvyklého úsilí inkrementálně se učícího systému (neuronové sítě). Pokud se vstupní proces chová podle předem naučeného schématu z tréninkového úseku (kdy byl tzv. „pod statistickou kontrolou“), jeho váhy se s novým vstupem signálu mění jen nevýrazně. Jakmile však dojde ke změně, váhy jednotlivých neuronů se začnou rychle měnit. To způsobuje změnu entropie, kterou lze následně detekovat jako příznak změny chování celého procesu.




2.3. Metody počítačové inteligence (CI)

Využití neuronových sítí - Learning Entropy

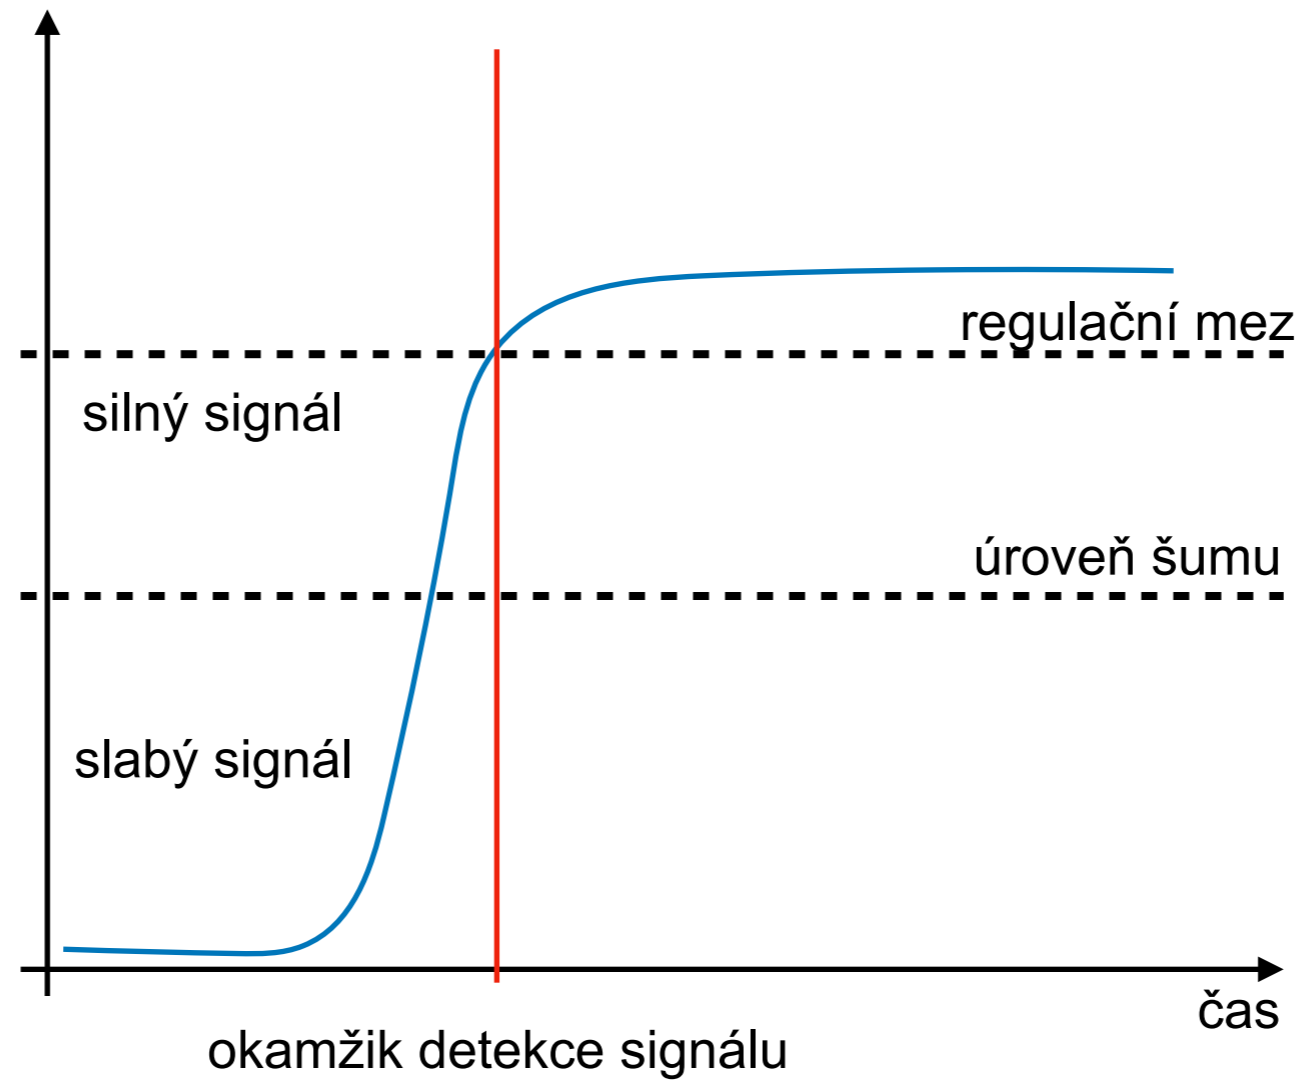
Learning Entropy - metoda detekce změny v chování sledovaného procesu, založená na detekci neobvyklého úsilí inkrementálně se učícího systému (neuronové sítě). Pokud se vstupní proces chová podle předem naučeného schématu z tréninkového úseku (kdy byl tzv. „pod statistickou kontrolou“), jeho váhy se s novým vstupem signálu mění jen nevýrazně. Jakmile však dojde ke změně, váhy jednotlivých neuronů se začnou rychle měnit. To způsobuje změnu entropie, kterou lze následně detekovat jako příznak změny chování celého procesu.




Bukovsky, I., Kinsner, W.: Learning Entropy: Information Concept for Learning Systems. Sensor Signal Processing for Defence (SSPD 2012), 2012




3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)



3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)




$$X_t = \epsilon_t$$

$$X_t = \epsilon_t + 0.3\epsilon_{t-3}$$


3. Statistické monitorování procesů (SPC)



$$X_t = \epsilon_t$$




$$X_t = \epsilon_t + 0.3\epsilon_{t-3}$$




Autokorelační funkce X_t


3. Statistické monitorování procesů (SPC)



$$X_t = \epsilon_t$$



$$X_t = \epsilon_t + 0.3\epsilon_{t-3}$$



Autokorelační funkce X_t

3. Statistické monitorování procesů (SPC)

Western Electric Rules


Western Electric Statistical Quality Control Handbook, 1956

3. Statistické monitorování procesů (SPC)

Western Electric Rules

Western Electric Statistical Quality Control Handbook, 1956

Shewhartův regulační diagram:



3. Statistické monitorování procesů (SPC)

Western Electric Rules


Western Electric Statistical Quality Control Handbook, 1956

Shewhartův regulační diagram:

zóna A: $(-\infty, -2\sigma)$ nebo $(2\sigma, +\infty)$

zóna B: $(-\infty, -\sigma)$ nebo $(\sigma, +\infty)$

zóna C: $(-\infty, 0)$ nebo $(0, +\infty)$



3. Statistické monitorování procesů (SPC)

Western Electric Rules

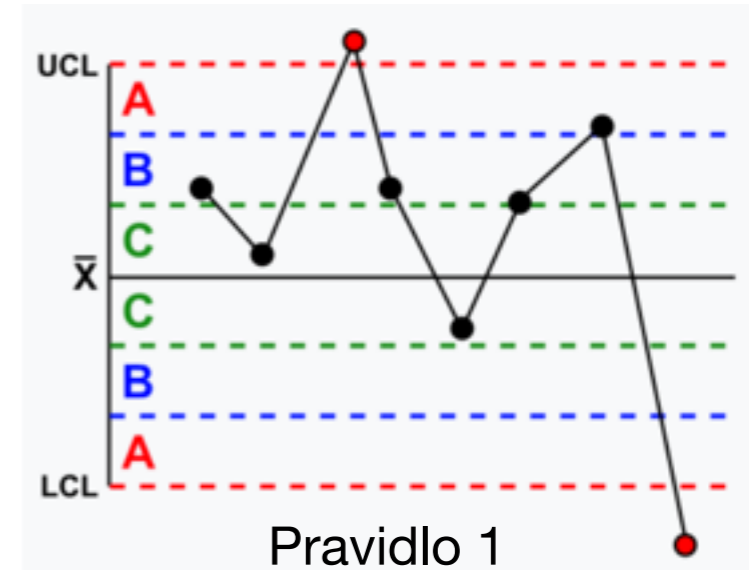
Western Electric Statistical Quality Control Handbook, 1956

Shewhartův regulační diagram:

zóna A: $(-\infty, -2\sigma)$ nebo $(2\sigma, +\infty)$

zóna B: $(-\infty, -\sigma)$ nebo $(\sigma, +\infty)$

zóna C: $(-\infty, 0)$ nebo $(0, +\infty)$



3. Statistické monitorování procesů (SPC)

Western Electric Rules





Western Electric Statistical Quality Control Handbook, 1956

Shewhartův regulační diagram:

zóna A: $(-\infty, -2\sigma)$ nebo $(2\sigma, +\infty)$

zóna B: $(-\infty, -\sigma)$ nebo $(\sigma, +\infty)$

zóna C: $(-\infty, 0)$ nebo $(0, +\infty)$



3. Statistické monitorování procesů (SPC)

Western Electric Rules



Western Electric Statistical Quality Control Handbook, 1956

Shewhartův regulační diagram:


zóna A: $(-\infty, -2\sigma)$ nebo $(2\sigma, +\infty)$

zóna B: $(-\infty, -\sigma)$ nebo $(\sigma, +\infty)$


zóna C: $(-\infty, 0)$ nebo $(0, +\infty)$



Pravidlo 2: 2003 \in A



Pravidlo 3: 4005 \in B



Pravidlo 4: 8008 \in C

3. Statistické monitorování procesů (SPC)

3. Statistické monitorování procesů (SPC)

Adaptivní meze:


3. Statistické monitorování procesů (SPC)

Adaptivní meze:




3. Statistické monitorování procesů (SPC)

Adaptivní meze:



3. Statistické monitorování procesů (SPC)


Adaptivní meze:



$\tilde{x}_n \in -A \Rightarrow$	$LCL_{n+1} = LCL_n + k_A\sigma, UCL_n = UCL_0,$
$\tilde{x}_n \in -B \Rightarrow$	$LCL_{n+1} = LCL_n + k_B\sigma, UCL_n = UCL_0,$
$\tilde{x}_n \in -C \Rightarrow$	$LCL_{n+1} = LCL_n + k_C\sigma, UCL_n = UCL_0,$
$\tilde{x}_n \in O \Rightarrow$	$LCL_{n+1} = LCL_0, UCL_n = UCL_0,$
$\tilde{x}_n \in C \Rightarrow$	$LCL_{n+1} = LCL_0, UCL_n = UCL_n - k_C\sigma,$
$\tilde{x}_n \in B \Rightarrow$	$LCL_{n+1} = LCL_0, UCL_n = UCL_n - k_B\sigma,$
$\tilde{x}_n \in A \Rightarrow$	$LCL_{n+1} = LCL_0, UCL_n = UCL_n - K_A\sigma$

3. Statistické monitorování procesů (SPC)

Adaptivní meze:



3. Statistické monitorování procesů (SPC)

ROAD-CUSUM \tilde{X}

$$\tilde{C}_{n+1}^+ = \max [0, \tilde{C}_n^+ - (\mu_0 + \delta_0) + \tilde{X}_n]$$
$$\tilde{C}_{n+1}^- = \max [0, \tilde{C}_n^- + (\mu_0 + \delta_0) - \tilde{X}_n]$$

3. Statistické monitorování procesů (SPC)

ROAD-CUSUM \tilde{X}

$$\tilde{C}_{n+1}^+ = \max [0, \tilde{C}_n^+ - (\mu_0 + \delta_0) + \tilde{X}_n]$$

$$\tilde{C}_{n+1}^- = \max [0, \tilde{C}_n^- + (\mu_0 + \delta_0) - \tilde{X}_n]$$

Adaptivní-CUSUM \tilde{X} regulační diagram $\delta_0 = 0.187$
hranice zón (A, B, C, O) = (4.34, 3.0, 2.5, 1.0)
(k_A, k_B, k_C) = (0.5, 0.25, 0.1)


3. Statistické monitorování procesů (SPC)

ROAD-CUSUM \tilde{X}

$$\tilde{C}_{n+1}^+ = \max [0, \tilde{C}_n^+ - (\mu_0 + \delta_0) + \tilde{X}_n]$$

$$\tilde{C}_{n+1}^- = \max [0, \tilde{C}_n^- + (\mu_0 + \delta_0) - \tilde{X}_n]$$

Adaptivní-CUSUM \tilde{X} regulační diagram $\delta_0 = 0.187$
hranice zón (A, B, C, O) = (4.34, 3.0, 2.5, 1.0)
(k_A, k_B, k_C) = (0.5, 0.25, 0.1)





3. Statistické monitorování procesů (SPC)

ROAD-CUSUM \tilde{X}

$$\tilde{C}_{n+1}^+ = \max [0, \tilde{C}_n^+ - (\mu_0 + \delta_0) + \tilde{X}_n]$$

$$\tilde{C}_{n+1}^- = \max [0, \tilde{C}_n^- + (\mu_0 + \delta_0) - \tilde{X}_n]$$

Adaptivní-CUSUM \tilde{X} regulační diagram $\delta_0 = 0.187$
hranice zón (A, B, C, O) = (4.34, 3.0, 2.5, 1.0)
(k_A, k_B, k_C) = (0.5, 0.25, 0.1)



Numerické výsledky: ARL pro různé diagramy pro data z $N(\delta, 1)$

Regulační diagram		shift δ						
		0.0	0.1	0.3	0.5	0.7	1.0	1.5
\bar{X}	Shewhart	500.2	405.3	128.1	41.5	16.3	5.0	1.7
	CUSUM	501.2	130.0	20.2	9.9	6.5	4.5	2.9
	EWMA	501.0	136.3	19.2	8.5	5.2	3.4	2.4
\tilde{X}	Shewhart	500.1	439.2	175.3	69.6	28.3	9.7	2.7
	CUSUM	502.0	151.4	26.2	13.1	8.7	5.7	3.8
	EWMA	499.2	165.4	24.4	10.3	6.4	4.0	2.7
\tilde{X}	Ad-CUSUM	504.1	124.9	24.5	11.7	7.9	5.4	3.7

Yang, L, Pai, S, Wang Y.R.: A novel CUSUM Median Control Chart. Proceedings of the International MultiConference of Engineers and Computer Scientists 2010 Vol. III, IMECS 2010, March 17 - 19, 2010, Hong Kong

Numerické výsledky:

Data: směs 94% $N(\delta, 1)$ a 6% $N(\delta, 6.25)$

Regulační diagram		shift δ						
		0.0	0.1	0.3	0.5	0.7	1.0	1.5
\bar{X}	Shewhart	87.1	78.0	48.2	24.5	13.8	5.7	2.7
	CUSUM	265.4	97.4	19.2	9.9	6.6	4.4	2.9
	EWMA	186.1	85.2	17.1	8.0	5.0	3.4	2.4
\tilde{X}	Shewhart	264.5	236.8	126.6	48.6	24.1	9.8	4.0
	CUSUM	430.0	139.4	26.8	12.8	8.6	5.8	3.8
	EWMA	343.9	127.4	23.3	10.0	6.2	4.0	2.7
\tilde{X}	Ad-CUSUM	466.2	121.5	24.1	11.8	7.9	5.4	3.7


Numerické výsledky:

Data: směs 94% $N(\delta, 1)$ a 6% $N(\delta, 6.25)$


Regulační diagram		shift δ						
		0.0	0.1	0.3	0.5	0.7	1.0	1.5
\bar{X}	Shewhart	500	447.7	276.7	140.6	79.2	32.7	15.5
	CUSUM	500	183.5	36.2	18.7	12.4	8.3	5.46
	EWMA	500	228.9	45.9	21.5	13.4	9.1	6.45
\tilde{X}	Shewhart	500	446.1	238.5	91.6	45.4	18.5	7.54
	CUSUM	500	162.1	31.1	14.9	10.0	6.74	4.42
	EWMA	500	185.2	33.9	14.5	9.01	5.82	3.93
\tilde{X}	Ad-CUSUM	500	130.3	25.9	12.7	8.47	5.79	3.97

$$RARL_C(\delta) = k \cdot ARL_C(\delta), \quad \text{where } k = \frac{ARL(0)}{ARL_C(0)}$$

3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)



$$\{t_k\}_{k=0}^{\infty} \quad t_k = \min \{t \geq 0 : t \geq t_{k-1}, X_t \geq \omega\}, \quad t_0 = 0$$


3. Statistické monitorování procesů (SPC)



$$\{t_k\}_{k=0}^{\infty} \quad t_k = \min \{t \geq 0 : t \geq t_{k-1}, X_t \geq \omega\}, \quad t_0 = 0$$

$$\{\tau_k\}_{k=1}^{\infty} \quad \tau_k = t_k - t_{k-1}$$


3. Statistické monitorování procesů (SPC)



$$\{t_k\}_{k=0}^{\infty} \quad t_k = \min \{t \geq 0 : t \geq t_{k-1}, X_t \geq \omega\}, \quad t_0 = 0$$

$$\{\tau_k\}_{k=1}^{\infty} \quad \tau_k = t_k - t_{k-1} \quad \tau \sim \text{Exp}(\lambda) \quad \lambda = P(X \geq \omega)$$

3. Statistické monitorování procesů (SPC)




$$\{t_k\}_{k=0}^{\infty} \quad t_k = \min \{t \geq 0 : t \geq t_{k-1}, X_t \geq \omega\}, \quad t_0 = 0$$


$$\{\tau_k\}_{k=1}^{\infty} \quad \tau_k = t_k - t_{k-1} \quad \tau \sim \text{Exp}(\lambda) \quad \lambda = P(X \geq \omega)$$

$$\tau_{\alpha}^* \leq -\frac{\ln(1 - \alpha)}{P(X \geq \omega)}$$


3. Statistické monitorování procesů (SPC)



3. Statistické monitorování procesů (SPC)

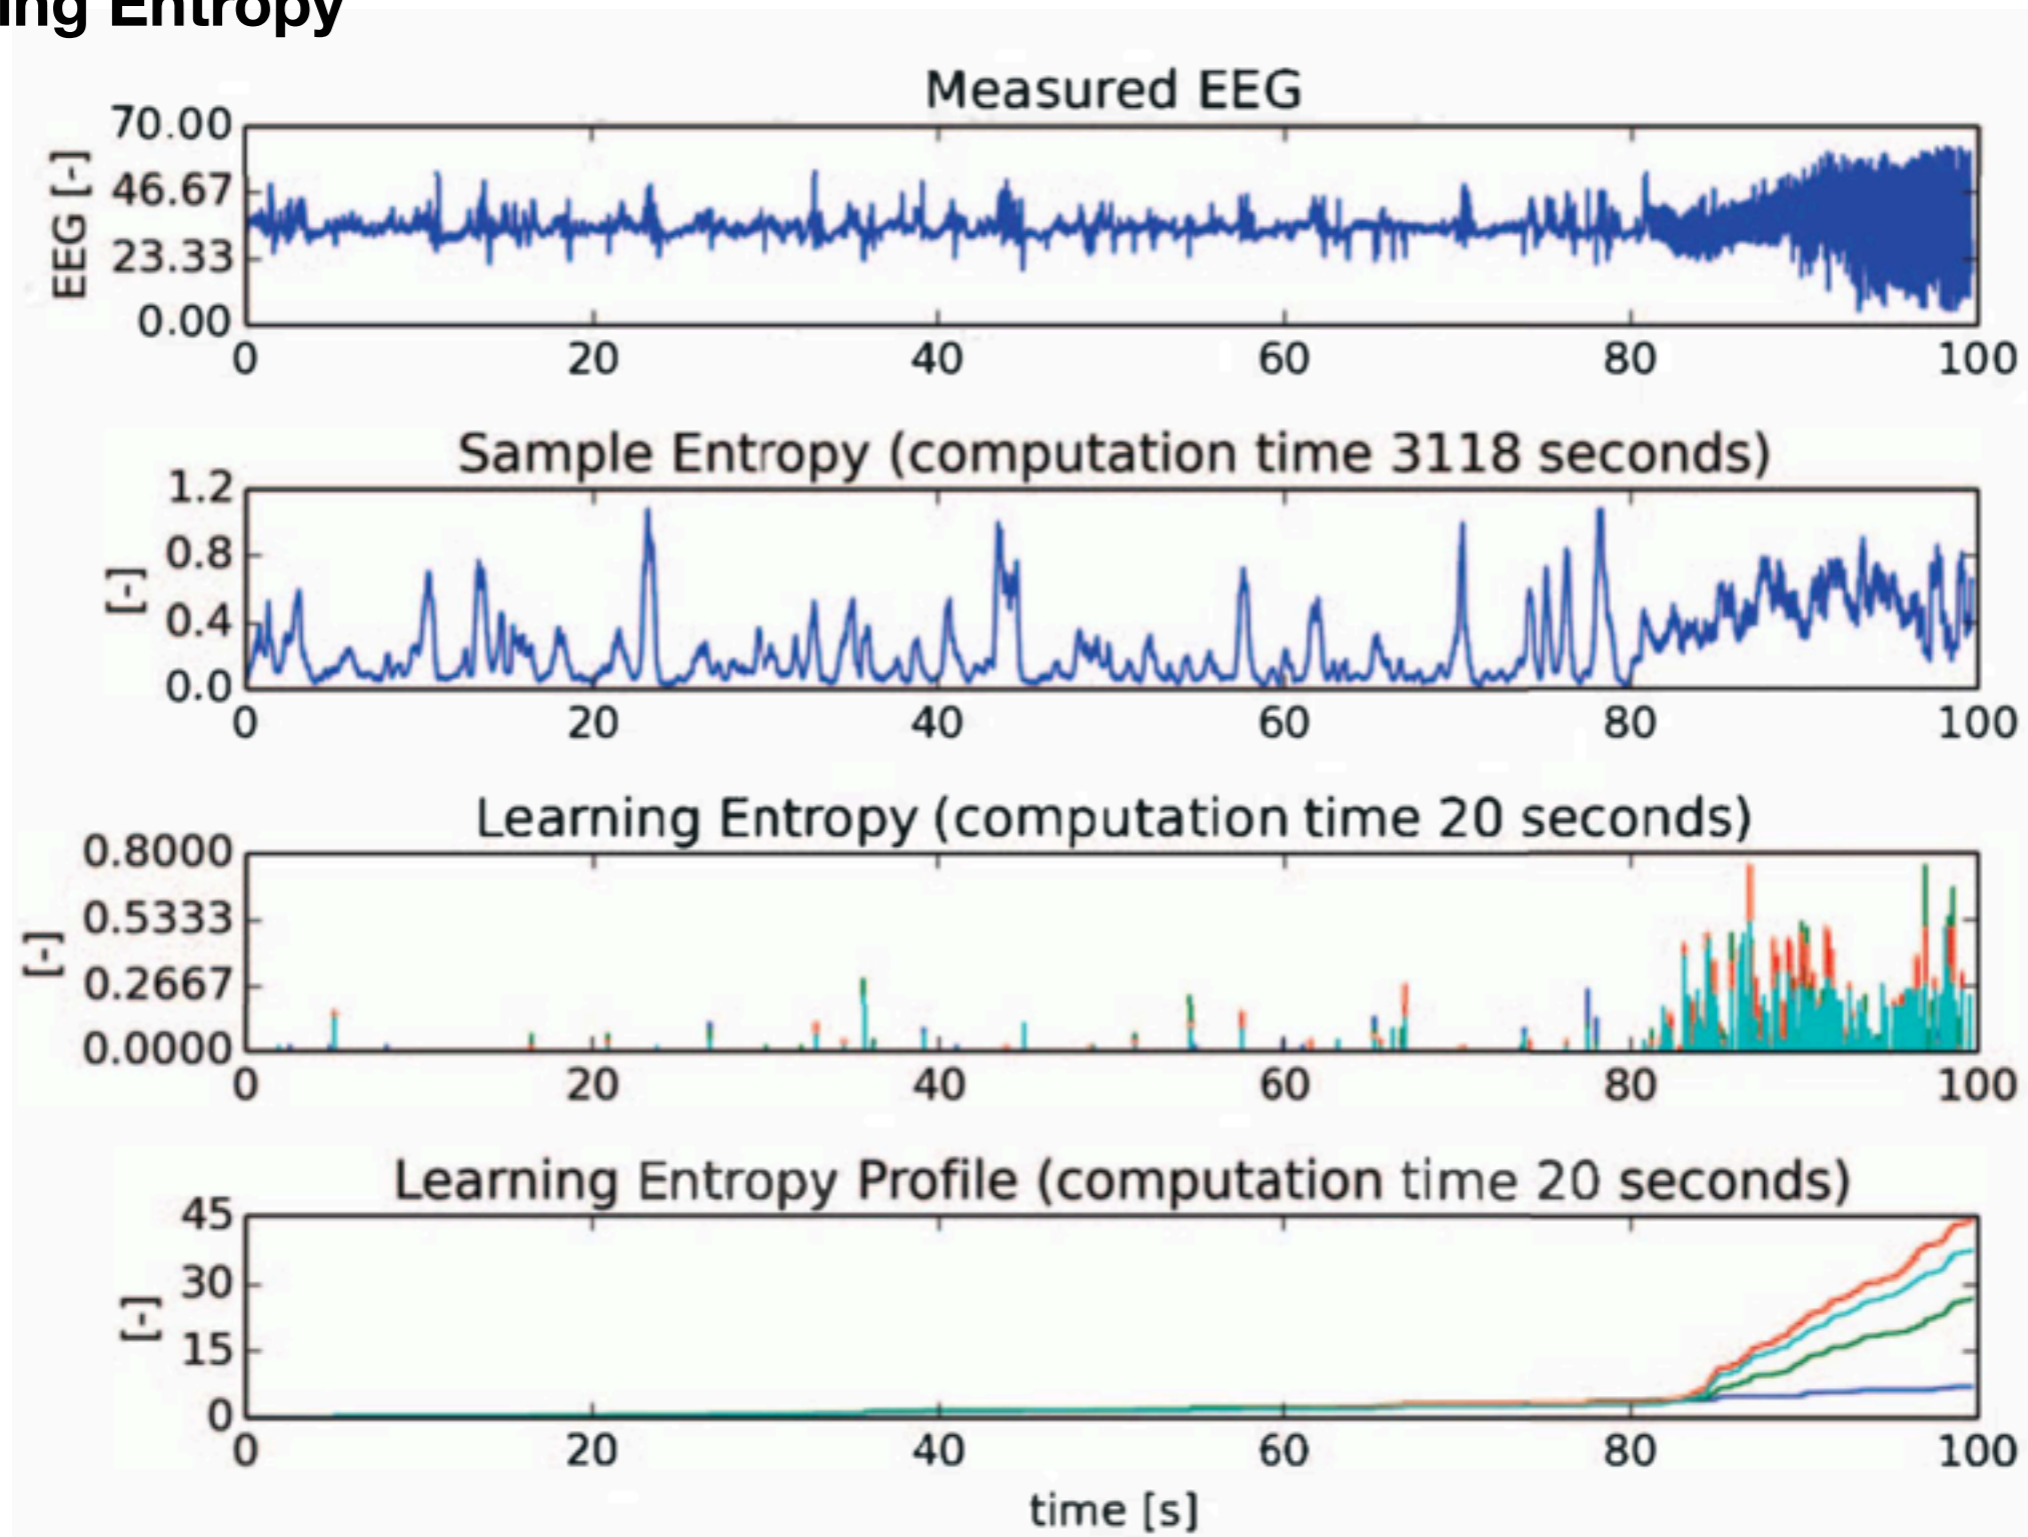


3. Statistické monitorování procesů (SPC)




3. Statistické monitorování procesů (SPC)


Learning Entropy




3. Statistické monitorování procesů (SPC)



3. Statistické monitorování procesů (SPC)



3. Statistické monitorování procesů (SPC)





EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání



CENTRUM LETECKÉHO A KOSMICKÉHO VÝZKUMU

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE
FAKULTA STROJNÍ
Projekt CZ.02.1.01/0.0/0.0/16_019/0000826

