

# **Analýza neurčitostí charakteristik vstupních parametrů do modelů šíření radionuklidů při únicích do životního prostředí**

**Část II : Volba grupy neurčitostí a metodika generování náhodných  
realizací vstupních vektorů modelů systému HAVAR**

*Dokumentace k etapě E 01 f) projektu 6/2003*



## Obsah

<b>1</b>	<b>ANOTACE</b> .....	<b>5</b>
<b>2</b>	<b>NÁHODNÉ CHARAKTERISTIKY GRUPY VSTUPNÍCH PARAMETRŮ MODELŮ</b> .....	<b>7</b>
	Příčiny existence neurčitostí vstupních parametrů.....	8
	Charakteristiky neurčitosti vstupních parametrů modelů.....	8
<b>3</b>	<b>ODEZVA NEURČITOSTI PREDIKCE MODELU NA NÁHODNÉ VSTUPNÍ PARAMETRY</b> .....	<b>10</b>
<b>4</b>	<b>METODIKY GENEROVÁNÍ REALIZACÍ VSTUPNÍCH NÁHODNÝCH VEKTORŮ</b> .....	<b>11</b>
	Metoda SRS (Simple Random Sampling).....	11
	Metoda LHS (Latin Hypercube Sampling).....	12
<b>5</b>	<b>GENERÁTORY NÁHODNÝCH ČÍSEL POUŽITÉ PRO PRAVDĚPODOBNOSTNÍ ODHADY V NOVÉM SYSTÉMU HAVAR</b> .....	<b>14</b>
	Interaktivní generátor LHS vyvinutý ve spolupráci FJFI - ÚTIA.....	18
	Profesionální produkt LHS EPITool.....	19
<b>6</b>	<b>STANOVENÍ NÁHODNÝCH CHARAKTERISTIK DÍLČÍCH KOMPONENT MODELU</b> .....	<b>22</b>
	Analýza neurčitostí v modelech šíření radioaktivity v atmosféře.....	22
	Konkrétní model atmosférické disperze s omezeným počtem vstupních náhodných parametrů. ....	25
	Neurčitosti v modelu potravních řetězců.....	26
<b>7</b>	<b>LITERATURA</b> .....	<b>29</b>
<b>8</b>	<b>PŘÍLOHA 1: METODIKA LHS POUŽITÁ V PRÁCI [16]</b> .....	<b>31</b>
<b>9</b>	<b>PŘÍLOHA 2: VÝBĚR NEURČITOSTÍ VSTUPNÍCH PARAMETRŮ ATMOSFÉRICKÉHO A DEPOZIČNÍHO MODELU</b> .....	<b>35</b>

<b>10</b>	<b>PŘÍLOHA 3: VÝBĚR NEURČITOSTÍ VSTUPNÍCH PARAMETRŮ MODELU POTRAVNÍCH ŘETĚZCŮ A VÝPOČTU DÁVEK.....</b>	<b>37</b>
	<b>Příloha 3a: Nejdůležitější parametry vybrané na základě studií citlivosti v [10] pro ingesční model ECOSYS.....</b>	<b>37</b>
	<b>Příloha 3b: Výběr parametrů v analýze neurčitostí provedené v [5] s užitím kódu OSCAAR.....</b>	<b>39</b>
	<b>Příloha 3c: Výběr parametrů v analýze neurčitostí provedené v [2] s užitím kódu MARC-2A .....</b>	<b>41</b>

## 1 ANOTACE

Přechod od deterministického modelování k pravděpodobnostnímu přístupu při hodnocení rizika úniku radionuklidů do životního prostředí je založen na analýze neurčitostí výsledných veličin v jednotlivých komponentách ekosystému (atmosférický a depoziční submodel, hydrologické submodely, potravní řetězce) a odpovídajícího hodnocení v oblastech modelování dávek a použitých dozimetrických modelů. Pravděpodobnostní metodika hodnocení radiologického rizika je v určitém přiblížení zaváděna do nové verze programu HAVAR a je koncepčně popsána v [1]. Prvním krokem této procedury je určování konkrétních náhodných realizací specifického vektoru vstupních parametrů. Pro každý submodel transportu je třeba stanovit rozměr  $N$  vektoru (počet relevantních vstupních parametrů plynoucích z předběžných procedur třídění a citlivostních studií) a dále korektně definovat náhodné charakteristiky jednotlivých vstupních parametrů. Konečně je třeba navrhnout a naprogramovat optimální výpočetní postupy pro generování realizací náhodných vektorů tak, aby bylo dosaženo věrohodných výsledků v přijatelném výpočetním čase. Předkládaná práce se zabývá právě touto problematikou kolem náhodných vektorů vstupních parametrů, která se pak aplikuje v dílčích submodelech šíření radionuklidů a hodnocení rizika jejich působení na lidský organismus.

Úvahy v této práci jsou zaměřeny na konkrétní aplikaci v rozšiřovaném kódu HAVAR. Některé obecnější úvahy a závěry z oblasti citlivostních studií provedené na základě rešerše shrnuje práce [24], která je myšlena jako úvodní 1. část problematiky zpracovávané v této práci.



## 2 NÁHODNÉ CHARAKTERISTIKY GRUPY VSTUPNÍCH PARAMETRŮ MODELŮ

Základním problémem je správný odhad rozsahu grupy vstupních parametrů a jejich náhodných charakteristik. Z literatury vyplývá, že model obvykle obsahuje velké množství vstupních parametrů, z nichž jen určitá část svými fluktuacemi významněji ovlivňuje výstup. To umožňuje provádět určitou redukci počtu parametrů a tak definovat optimální rozměr náhodného vstupního vektoru  $\mathbf{X} \equiv [X_1, X_2, \dots, X_N]$ .

Pro náhodný vektor  $\mathbf{X}$  lze zavést některé jeho číselné (maticové) charakteristiky. K základním patří vektorová střední hodnota a kovarianční matice. Střední hodnota náhodného vektoru se definuje jako vektor středních hodnot jeho jednotlivých složek, tedy:

$$E[\mathbf{X}] = \{ E[X_1], E[X_2], \dots, E[X_N] \} \quad (1a)$$

Pro dvě náhodné veličiny  $X_1$  a  $X_2$  je kovariance  $\text{cov}(X_1, X_2)$  definována podle:

$$\text{cov}(X_1, X_2) = E[ (X_1 - E[X_1]) \cdot (X_2 - E[X_2]) ] \quad (1b)$$

přičemž pro  $X_1 = X_2$  přechází  $\text{cov}(X_1, X_2)$  na rozptyl  $D$ .

Kovarianční matice  $C(\mathbf{X})$  náhodného vektoru  $\mathbf{X} \equiv [X_1, X_2, \dots, X_N]$  je zapisována schématem:

$$C(X) = \begin{bmatrix} D(X_1) & \text{cov}(X_1, X_2) & \dots & \text{cov}(X_1, X_N) \\ \text{cov}(X_2, X_1) & D(X_2) & \dots & \text{cov}(X_2, X_N) \\ \dots & \dots & \dots & \dots \\ \text{cov}(X_N, X_1) & \text{cov}(X_N, X_2) & \dots & D(X_N) \end{bmatrix} \quad (1c)$$

Rozsah grupy (to znamená počet  $N$  relevantních vstupních parametrů) se odhaduje na základě analýzy významnosti vlivu parametru na výstupní veličiny (předběžné třídění a citlivostní studie, nevýznamné parametry jsou dále charakterizovány pouze deterministicky jejich nominálními hodnotami).

Základním výpočetním schématem pravděpodobnostního přístupu k problematice odhadů radiologických důsledků je mnohonásobné opakování výpočtů s konkrétními realizacemi vstupního náhodného vektoru. Hlavním důvodem je složitost a nelinearita modelu, a tak pouze aplikace Monte Carlo postupů umožňuje dosáhnout realistických výsledků. Proto je nezbytné v prvním kroku zvolit vhodnou metodu vzorkování (generování  $N$ -tic realizací vstupního náhodného vektoru  $\mathbf{X}$ ), a to jak s ohledem na dostatečně velký počet realizací tak vzhledem ke korektnímu zahrnutí skutečných korelací mezi vstupními parametry. V prvním případě jde o volbu optimálního výběrového algoritmu (v dalším je uvedena a použita metoda LHS nahrazující hrubé Monte Carlo modelování).

Konečně podrobnější analýza korelací mezi jednotlivými vstupy musí vést na jedné straně k potlačení případných falešných korelací vnášených do výpočtu v důsledku nedokonalosti algoritmu stratifikovaného vzorkování, na druhé straně je třeba zahrnout korelace mezi páry vstupů deklarovaných na základě expertních doporučení. Oba efekty umožňuje akceptovat metodologie popsána např. v [4] (původní autoři Iman, Conover), kdy daná korelační matice

je použita při operacích s generovanými náhodnými hodnotami. Výsledkem je zachování daných pořadových korelací ve výsledné transformaci.

### **Příčiny existence neurčitostí vstupních parametrů**

Zdrojem neurčitostí vstupů do modelů šíření jsou:

- Fluktuační vstupních parametrů způsobené jednak jejich možným stochastickým charakterem, neurčitostmi ve stanovení jejich hodnot v důsledku nedostatečné determinace parametrů a konečně v důsledku chyb měření při případném stanovení jejich hodnot na základě měření. Tyto neurčitosti jsou někdy označovány jako typ A.
- Zjednodušená matematická formulace při popisu složitých fyzikálních procesů zaváděných do modelů, nedokonalost modelu při popisu fyzikální podstaty (typ B).
- Chyby v důsledku numerického řešení.
- Nekompletní popis uvažovaného scénáře při únicích radionuklidů do životního prostředí, neurčitosti při definici zdrojového členu úniku.

Je třeba zdůraznit, že v souvislosti s determinací charakteru neurčitostí jsou do modelování vnášeny další subjektivní prvky, které mohou být potlačeny pouze na základě expertního odhadu a posuzování kvalifikovanými odborníky. Jakékoliv odhady spolehlivosti musí tedy vycházet z předchozí hluboké analýzy neurčitostí základních vstupních parametrů. Proto také v této práci jsou přebírány zkušenosti získané při vývoji významných světových kódů a jsou aplikována doporučení vzešlá z jednání předních expertů z oboru ( tzv. elicitačních procedur - např. [7], [8]) a založená na obecné shodě jejich názorů na jednotlivé efekty.

### **Charakteristiky neurčitostí vstupních parametrů modelů**

Na základě obecně přijatého souhlasu je nutné deklarovat následující vlastnosti náhodných vstupních parametrů modelů:

- Myslitelný rozsah jejich hodnot (např. horní a dolní meze možných hodnot)
- Typ rozdělení náhodného parametru
- Vzájemnou závislost mezi náhodnými hodnotami parametrů

#### **K určení typu rozdělení:**

Rozhodující roli hraje korektní specifikace druhého bodu týkajícího se typu rozdělení, ke které je nutné respektovat obecně publikovaná expertní doporučení (pokud jsou pro daný případ k dispozici). Je obecným pravidlem, že jen zřídka lze experimentálně podpořit konkrétně provedený závěr. Pokud jsme nuceni přijmout vlastní rozhodnutí, je třeba si uvědomit možný subjektivní prvek, který by při povrchním postupu mohl vést ke zkreslení výsledků. Obecně doporučovaný postup pro tento případ říká, že pokud máme minimální znalosti o možných náhodných charakteristikách, je rozumné se omezit na rovnoměrné rozdělení v rámci definovaného rozsahu.



Jestliže bude k dispozici další expertní znalost směrem k podrobnější znalosti typu rozdělení, lze akceptovat příslušný lépe odpovídající typ jako je unimodální a symetrické rozdělení (např. trojúhelníkového typu) nebo rozdělení respektující předpokládané zkosení k dolní či horní mezi. Pro fluktuace většího rozsahu je obvykle dávana přednost pracovat s logaritmy příslušných hodnot a přizpůsobit uniformní, trojúhelníkové nebo normální rozdělení na logaritmická (LogUniform, LogTriangular, LogNormal). Je třeba mít na paměti [6], že často i experti obtížně formulují průběhy hustoty pravděpodobnosti v limitních dolních a horních oblastech. Je proto lepší nadefinovat určité rozumné hraniční body a uvažovat omezená (truncated) rozdělení. Pravděpodobnostní odhady následků úniků budou reprezentativní jen tehdy, pokud předchází proces přiřazení náhodných charakteristik všem důležitým vstupním parametrům bude korektní.

V dalším jsou respektovány následující typy rozdělení, které mohou být volitelně použity v pravděpodobnostním modelu nového systému HAVAR:

- normální
- lognormální
- omezené normální
- rovnoměrné (uniformní)
- diskrétní rovnoměrné
- trojúhelníkové

Uvažuje se další rozšíření o některá speciální rozdělení (beta rozdělení, loguniformní), případně zavedení rozdělení nesymetrických (trojúhelníkové nepravidelné). Uživatelské interaktivní volby pro jednotlivé parametry pak vstupují do následné procedury generování realizací náhodného vstupního vektoru.

#### K otázce korelací:

Pokud se týká vzájemné závislosti mezi náhodnými hodnotami parametrů, je třeba zjištěné závislosti promítnout do metody generování náhodných vzorků. V případě určité míry vzájemné závislosti fluktuací dvou vstupních parametrů je třeba zavést též určitou závislost při generování párů náhodných vzorků obou parametrů. Jde tedy o to, akceptovat při proceduře generování skutečné korelace. Na druhé straně je třeba potlačit falešné korelace, které se mohou při procesu generování náhodných vzorků vyskytnout jako důsledek použitého algoritmu (např. při párování náhodných výběrů u metody LHS – viz poznámka dále).

#### Převod veličin do standardizovaného tvaru:

Pro konkrétní algoritmus generování náhodných vzorků je užitečné rozdělit náhodný parametr  $R$  do dvou částí podle schématu:

$$R = c * R_{ref} \quad (2)$$

kde  $c$  je „standardizovaná“ náhodná veličina s vhodným rozdělením hustoty pravděpodobnosti a  $R_{ref}$  je tak zvaný nejlepší odhad  $R$  někdy označovaný také jako referenční či nominální hodnota. Separace podle (2) je zřejmě výhodná i z hlediska vytváření

zdrojového kódu pro pravděpodobnostní model. Bezrozměrné náhodné proměnné  $c$  jsou v tabulkách přiložených na konec zprávy obvykle označovány jako faktory.

Závěrem této kapitoly poznamenejme, že jak redukce počtu vstupních náhodných parametrů tak jejich charakteristiky náhodného rozdělení byly v této práci odhadnuty na základě rozsáhlé rešerše světových kódů, citovaných na konci zprávy v odkazech na literaturu. Jedná se o systémy COSYMA, UFOMOD, MACSS, OSCAAR, LISA, GENII, GESMAC a další.

### 3 ODEZVA NEURČITOSTI PREDIKCE MODELU NA NÁHODNÉ VSTUPNÍ PARAMETRY

Analýza neurčitostí se zabývá šířením fluktuací vstupních parametrů modelem. Modelování transportu radionuklidů a posuzování radiologických dopadů úniku radionuklidů na populaci musí uvažovat celý řetěz šíření od místa úniku až po jednotlivé cesty možného ozáření člověka. Celý proces se popisuje vzájemně provázanými submodely, z nichž hlavní jsou:

- Atmosférický a depoziční modul
- Transport aktivity potravními řetězci
- Dozimetrický model pro odhady dávek

Výstupem modelů jsou v obecném případě náhodná pole hodnot (jak z hlediska prostorového tak časového) nejrůznějších veličin. V nejjednodušším případě sledování fluktuací jediné skalární výstupní hodnoty  $V$  model je schématicky vyjádřen podle:

$$V = F(X_1, X_2, \dots, X_N) \quad (3)$$

Interpretací vlivu náhodných fluktuací vstupů na výstupní veličiny se zabývají různé metodiky analýzy neurčitostí. V systému RODOS i COSYMA jsou z diskrétních nagenovaných hodnot konstruovány distribuční funkce různých cílových veličin jako jsou koncentrace aktivity v dílčích komponentách, dávky záření od různých cest apod. Jsou používány jak CDF (Cumulative Density Function) tak CCDF (Complementary Cumulative Density Function) závislosti, ze kterých lze odhadnout rozsah fluktuací výstupů nebo pravděpodobnosti přestoupení určitých referenčních hodnot. Dále je prováděna kvantifikace neurčitostí na základě percentilů resp. jejich poměrů. Jsou určovány výběrové průměry a příslušné intervaly spolehlivosti. Po určení těchto základních statistik následuje podrobnější analýza ve směru dalších studií citlivosti s cílem určit velikost vlivu jednotlivých vstupních parametrů, seřadit je podle velikosti jejich vlivu a odhalit příslušné korelace. Přitom jsou užívány techniky :

- Vyšetřování závislostí na rozptylových diagramech
- Užití metodik regresní analýzy a asociovaných statistických testů, postupná regresní analýza
- Určování korelací a parciálních korelací pro vzorky pozorování  $(x_k, v_k)$ ,  $k=1, \dots, K$ ; (výběrový resp. Pearsonův korelační koeficient)

- Transformace pořadových charakteristik, Spearmanův a Kendallův pořadový koeficient korelace

Závěrem shrneme, že matematický model šíření radionuklidů je silně nelineární systém a ani např. pro zjednodušený Gaussův model přímočarého šíření není možné najít analytickou funkci alespoň přibližně popisující výsledek. Z obecného pohledu jsou používány dva přístupy k modelování náhodných charakteristik predikce  $V$  v závislosti na fluktuacích vstupů  $\mathbf{X}$ . Jedná se o analytické metody a numerický přístup. Podrobněji se oběma metodami cílenými na vývoj programu HAVAR zabývá práce [1]. V následujícím odstavci obrátíme pozornost zpět k původnímu nezbytnému kroku pravděpodobnostního přístupu, kterým je efektivní metodika generování náhodných hodnot vstupních parametrů.

#### 4 METODIKY GENEROVÁNÍ REALIZACÍ VSTUPNÍCH NÁHODNÝCH VEKTORŮ

Zásadní důležitost má volba vhodné metodiky generování realizací vstupních náhodných vektorů. Z různých možných strategií uvedeme dva postupy generování konkrétních realizací  $N$ -rozměrného náhodného vektoru vstupních parametrů. První z nich je základní Monte-Carlo metoda SRS (Simple Random Sampling), druhou je efektivnější metoda LHS (Latin Hypercube Sampling).

##### Metoda SRS (Simple Random Sampling)

Myšlenka metody je koncepčně jednoduchá. Je třeba spočítat neznámou  $z$  z rovnice :

$$r = \int_{-\infty}^z f(x) dx \quad (4)$$

kde  $r$  je náhodně zvolené číslo v intervalu  $\langle 0,1 \rangle$  a  $f(x)$  je hustota pravděpodobnosti dané náhodné veličiny  $X$ . Nalezené  $z$  je hledaná náhodná hodnota náhodné veličiny  $X$ . Pro případ náhodného vstupního vektoru  $\mathbf{X}$  dimenze  $N$  tento postup opakujeme pro každou jeho složku a získáme tak  $N$ -tici vygenerovaných náhodných hodnot veličiny  $\mathbf{X}$ . Obdobným způsobem se generují další  $N$ -tice konkrétních čísel a tímto způsobem získáme  $K$  náhodných realizací (číselných  $N$ -tic), které lze uspořádat do matice:

$$\mathbf{A}^{K,N} = \begin{pmatrix} z_{11} & \cdots & z_{1N} \\ \vdots & \cdots & \vdots \\ z_{K1} & \cdots & z_{KN} \end{pmatrix} \quad (5)$$

Jeden řádek předchozí matice představuje vždy jednu konkrétní realizaci náhodného vstupního vektoru o  $N$  prvcích. Z praktických důvodů je velikou nevýhodou metody SRS nutnost počítat pro poměrně vysokou hodnotu realizací  $K$  pro dosažení nestranných odhadů.

## Metoda LHS (Latin Hypercube Sampling)

Předchozí metoda SRS představuje konvenční obecný přístup založený na hrubém Monte Carlo vzorkování. Je však nutné uskutečnit velmi rozsáhlý výběr a tomu úměrný počet volání vlastního systému na určování výstupních veličin modelu, což sebou přináší značné požadavky na výpočetní techniku. Tyto důvody vedly k návrhu modifikované Monte Carlo procedury umožňující provádět pravděpodobnostní odhady mnohem efektivněji. Princip metody spočívá v rozdělení rozsahu každého vstupního parametru  $i$  ( $i=1, \dots, N$ ) na  $K$  vzájemně se nepřesahujících částí na základě stejné pravděpodobnosti výskytu v každé části. V každé této části je náhodně vybrána jedna hodnota parametru  $i$  (na základě skutečné hustoty pravděpodobnosti v tomto intervalu). Například pro  $i=1$  je takto generováno  $K$  konkrétních hodnot parametru  $X_1$ . Obdobný postup se aplikuje na další parametr  $X_2$ , kdy je opět zvoleno  $K$  hodnot v příslušných podintervalech jeho rozsahu. Podstatou metody LHS je náhodné párování konkrétních realizací takto získaných  $K$ -tic náhodných hodnot. Na obrázku 1 je tento postup ilustrován na příkladě dvou proměnných  $X_1$  a  $X_2$  pro počet subintervalů  $K=5$ , kde:

$$\begin{aligned} P(-\infty < X_1 \leq A) &= P(A < X_1 \leq B) = P(B < X_1 \leq C) = P(C < X_1 \leq D) = P(D < X_1 < \infty) = \\ &= 0.2 \end{aligned} \tag{6}$$

a dále pro parametr  $X_2$  omezený na intervalu  $< X_{2min}; X_{2max} >$  obdobně platí pro přijaté rozdělení na subintervaly vztah:

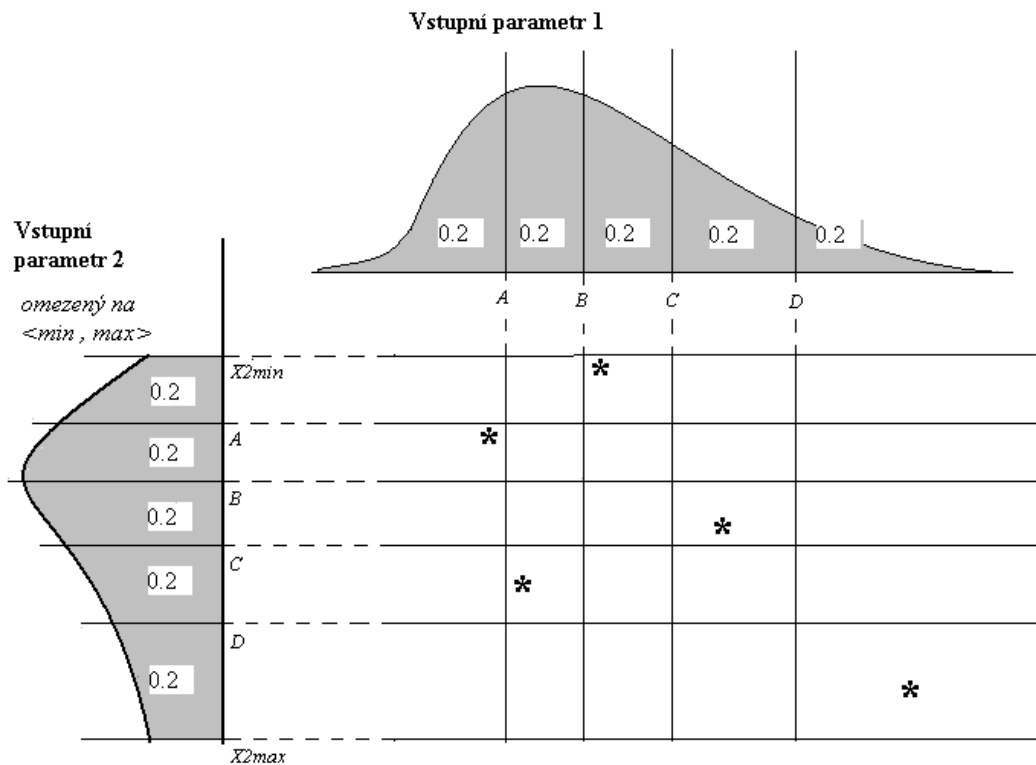
$$\begin{aligned} P(X_{2min} \leq X_2 \leq A) &= P(A < X_2 \leq B) = P(B < X_2 \leq C) = P(C < X_2 \leq D) = \\ &= P(D < X_2 \leq X_{2max}) = 0.2 \end{aligned} \tag{7}$$

Výsledek náhodného párování  $K$ -tic je na obrázku 1 znázorněn vždy hvězdičkou. Pro další náhodnou proměnnou jsou tyto základní páry opět kombinovány s obdobně nagenеровanou pěticí hodnot další veličiny  $X_3$  a tak je vytvořeno  $K$  trojic. Algoritmus pokračuje pro další proměnné až nakonec je získáno  $K$   $N$ -tic realizací vstupního náhodného vektoru. Podrobnější úvahy týkající se omezení na volbu hodnoty  $K$  a další detaily LHS metody jsou popsány například v [13,15].

***Poznámka:** Kolem teorie LHS existuje několik dalších důležitých otázek. Předně je to otázka potlačení nechtěných korelací mezi vstupními parametry, které jsou do výpočtu vnášeny navzdory náhodnému výběru při párování nagenеровaných hodnot. Jsou navrženy modifikované metodiky LHS, které vkládáním určitých restrikcí na výběrové permutace umí potlačit zdánlivé korelace a naopak umožní respektování reálných vzájemných korelací jednotlivých vstupních parametrů.*

1. *Příkladem zahrnutí skutečných korelací je postup uvedený v [9], kde jsou specifikovány dvojice vstupních parametrů, pro které je absolutní hodnota korelačního koeficientu větší než 0.2. Tak například korelační koeficient mezi rychlostí suché depozice pro aerosoly a pro elementární jód je 0.3. Je uváděna silná korelace mezi koeficienty empirické formule pro vymývání srážkami. Vyššími hodnotami korelačního koeficientu jsou charakterizovány i závislosti mezi disperzními koeficienty pro dílčí kategorie stability atmosféry. Obdobně v práci [2] vztahené k analýze neurčitosti s užitím kódu MARC- 2A (NRPB) je pro horizontální disperzi vlečky uvažována jednak fluktuace směru větru  $\sigma_{yw}$  s periodou řádově desítky minut a dále pak druhá složka  $\sigma_{yb}$ , způsobená atmosférickou turbulencí v časové škále několik málo minut. Při analýze*

neurčitostí se však uvažuje úplná závislost disperzních parametrů  $\sigma_{yt}$  a  $\sigma_z$  v horizontálním a vertikálním směru a tak pouze jeden z nich vstupuje do pravděpodobnostních odhadů.



**Obr.1 : Schématické znázornění principu algoritmu LHS (Latin Hypercube Sampling)**

(počet náhodných vstupů = 2, počet rovnoměrných úrovní rozdělení rozsahu pdf = 5)

Metoda LHS obecně náleží do modelů tzv. vrstveného vzorkování (stratified sampling), které respektují vzorkování realisticky a konzistentně. Obecně se ukazuje, že při stejné přesnosti dosažených výsledků modelování potřebuje metoda LHS menší počet náhodných realizací (a tím i nutný počet opakování výpočtu celého modelu). Párované výběry při LHS nevykazují tak velké vzájemné odlišnosti, jak se může stát mezi jednotlivými realizacemi při hrubé metodě SRS.

## 5 GENERÁTORY NÁHODNÝCH ČÍSEL POUŽITÉ PRO PRAVDĚPODOBNOSTNÍ ODHADY V NOVÉM SYSTÉMU HAVAR

Pokud se týká vlastních algoritmů generování pro různé typy rozdělení, každá významnější knihovna programů nabízí generátory pseudonáhodných čísel. Produkt FORTRAN VISUAL nabízí online knihovnu IMSL, kde jsou k dispozici procedury:

Typ rozdělení	volání
Uniform (0,1) ..... <i>(lineární kongruenční generátor)</i>	RNUN
Uniform (0,1), function form.....	RNUNF
General discrete distribution, using alias method.....	RNGDA
Logarithmic .....	RNLGR
Discrete uniform.....	RNUND
Beta.....	RNBET
Chi-squared.....	RNCHI
Cauchy.....	RNCHY
Exponential .....	RNEXP
Mixture of two exponentials.....	RNEXT
Gamma.....	RNGAM
Lognormal.....	RNLNL
Normal, using acceptance/rejection .....	RNNOA
Normal, function form of RNNOR.....	RNNOF
Normal, using inverse CDF .....	RNNOR
Stable.....	RNSTA
Student's t.....	RNSTT
Triangular .....	RNTRI
Von Mises.....	RNVMS
Weibull.....	RNWIB

Z vícerozměrných rozdělení uved'me:

Multinomial .....	RNMTN
Multivariate normal .....	RNMVN

V úvahu také připadá statistický aparát systému MATLAB, který by mohl být využíván offline vzhledem k běhům programu HAVAR takovým způsobem, že by náhodné realizace vstupního vektoru mohly být nagenеровány předem a při cyklech HAVAR by se vždy načítaly ze vstupního souboru. Kromě nabídky pseudonáhodných generátorů jsou k dispozici dílčí LHS algoritmy ve formě *m-souborů*, ze kterých lze zkonstruovat LHS proceduru pro vícerozměrný vstupní náhodný vektor:

*Vícerozměrná rozdělení, bez korelací:*

latin\_hs : latin hypercube sampling (LHS) of multivariate normal

distribution  
 lhsu : LHS of multivariate uniform distribution  
 lhs\_empir : LHS of multivariate empirical distribution  
 inv\_gauss : Inversion function to normal distribution function


*Vícerozměrná rozdělení, s korelací:*

lhs\_iman : LHS multivariate normal distribution, method of Iman & Conover  
 lhs\_stein : LHS multivariate normal distribution, method of Stein  
 ransamp : random sampling from multivariate normal distribution  
 lhs\_empirco : LHS of multivariate empirical distribution


*Utility:*

ltqnorm : inverse of normal CDF (from Peter J. Acklam)  
<http://home.online.no/~pjacklam/notes/invnorm/index.html>  
 ranking : ranking of data

Těchto algoritmů lze s výhodou využít v procesu generování náhodných výběrů z různých typů rozdělení. Tak například jeden z nejrozšířenějších typů je normální resp. logaritmičticky-normální rozdělení. Mají následující průběh charakteristik:



obr. 2a Hustota normovaného normálního rozdělení



obr. 2b Distribuční funkce normovaného normálního rozdělení

Inverzní funkci k distribuční funkci podle obr. 2b lze užít k transformaci hodnot generovaných z uniformního rozdělení  $U(0,1)$  pro normální rozdělení  $N(\mu, \sigma)$ , kdy hodnota z  $U$  rozdělení se nanese na osu  $y$ , jí se proloží rovnoběžka s osou  $x$  a najde se průsečík s distribuční funkcí.  $X$ -ová souřadnice průsečíku je hledaná přetransformovaná hodnota pro normální rozložení. Je zřejmé, že hledat tuto hodnotu takto graficky je nepraktické. Proto jsou k dispozici různá přibližná analytická vyjádření pro inverzní distribuční funkci některých typů rozdělení. Lze využít zmíněné m-soubory z MATLAB systému:

```

function y = inv_gauss(p,mu,sigma)
% Inverse of the Gaussian (normal) cumulative distribution function (cdf)
% input:
%   mu   = mean,
%   sigma = standard deviation
% output:
%   y    = inverse of the normal cdf
%
y = (-sqrt(2)*sigma).*erfcinv(2*p) + mu;

```

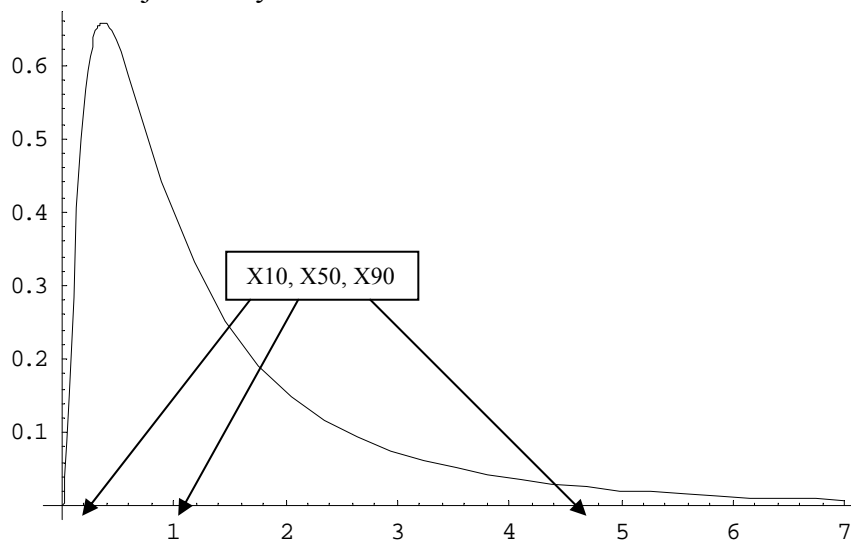
V [12] jsou uváděny analytické výrazy pro přibližné analytické vyjádření inverzní CDF (Cumulative Density Function – distribuční funkce) normovaného normálního rozdělení  $N(0,1)$ , na které lze převést obecné  $N(\mu, \sigma)$  transformací  $t = \mu + \sigma \cdot x$ .

Důležitou funkcí je též procedura `Itqnorm(p)` pro přesnější výpočty p-quantilů normálního rozdělení pro velmi nízké pravděpodobnosti. Pro zvolenou pravděpodobnost  $P$  vracejí hodnotu  $z$ , splňující  $\Pr\{X < z\} = P$ , kde  $X$  má normální rozdělení.

Poměrně často navrhované rozdělení vstupních parametrů v oblasti pravděpodobnostního hodnocení radiologického rizika jsou logaritmicko-uniformní a logaritmicko-normální rozdělení. Náhodná veličina  $X$  má lognormální rozdělení, pokud její logaritmus má normální rozložení  $N(\mu, \sigma)$ . Rozdělení hustoty pravděpodobnosti pro lognormální veličinu má tvar:


$$f(x) = \frac{1}{x \cdot \sigma \cdot \sqrt{2 \cdot \pi}} \cdot \exp \left[ -\frac{(\log(x) - \mu)^2}{2 \cdot \sigma^2} \right] \quad \text{pro } (0 < x < \infty) \quad (8)$$

Grafické vyjádření ukazuje na nesymetričnost rozdělení:



obr. 3a Hustota pravděpodobnosti lognormálního rozdělení (schématicky zobrazeny hodnoty kvantilů  $X_{10}$ ,  $X_{50}$ ,  $X_{90}$ )





obr. 3b Distribuční funkce lognormálního rozdělení

Střední hodnota a rozptyl logaritmicky normálně rozdělené veličiny  $X$  mají tvar:

$$E(X) = \exp(\mu + \sigma^2 / 2) \quad , \quad D^2(X) = \exp(2 \cdot \mu + \sigma^2) \cdot (\exp(\sigma^2) - 1) \quad (9)$$

Obdobně jako pro normální rozdělení jsou v [12] uváděny analytické výrazy pro přibližné analytické vyjádření CDF logaritmicky normálního rozdělení, kdy se využívá vztahů pro normální rozdělení veličiny  $y$  s následující transformací  $x=e^y$ .

Neurčitosti vstupních parametrů jsou v literatuře zadávány různě. Buď zjednodušeně pouze jejich rozsahem nebo přesněji jejich parametry rozdělení ( $\mu$ ,  $\sigma$ ). Druhý případ je někdy uváděn zjednodušeně, kdy jsou zadány pouze hodnoty kvantilů (viz např. obr 3a):

$$X_{10} = 10\% \text{ kvantil}$$

$$X_{50} = 50\% \text{ kvantil}$$

$$X_{90} = 90\% \text{ kvantil}$$

Příčemž  $\alpha$ .100-procentní kvantil  $X_\alpha$  je definován jako:

$$X_\alpha = \inf \{ x \in \mathbb{R}: F(x) \geq \alpha \}$$

I v tomto případě je však možno přibližně vypočítat parametry náhodného rozdělení. V případě lognormálního rozdělení podle obr. 3b lze ze symetrických kvantilů spočítat:

$$\mu = (\ln(X_{10}) + \ln(X_{90})) / 2$$

$$\sigma = (\ln(X_{90}) - \mu) / Z_{90}$$

kde  $Z_{90} \approx 1.28$  je tabelovaný 90% kvantil standardního normálního rozdělení.

### *Interaktivní generátor LHS vyvinutý ve spolupráci FJFI - ÚTIA*

Pro těsnější integraci metody LHS byl vyvinut interaktivní subsystém pro LHS. V rámci řešeršního úkolu zadaného katedrou matematiky FJFI, ČVUT vypracoval studující Luboš Housa práci [16], jejíž součástí je i funkční interaktivní panel pro LHS aplikaci zobrazený na obrázku 4. Jsou podporována rozdělení :

- normální
- lognormální
- omezené normální
- rovnoměrné (uniformní)
- diskrétní rovnoměrné
- trojúhelníkové

Vzhledem k záměru použít panel v nové verzi programového systému HAVAR jsou bližší podrobnosti o konstrukci LHS procedury převzaty z práce [16] a uvedeny v příloze 1 této zprávy.

**Nastavení generování náhodných veličin**

Počet náhodných veličin : 6

Počet vygenerovaných n-tic : 1000

Vlastnosti náhodných veličin

1.	nominální hodnota	1	rozdělení	uniformní	levá mez	0.5	ořezání	3 - sigma	poč.hodnot	11
2.	nominální hodnota	1	rozdělení	ořezané normální	$\mu$	1	ořezání	3 - sigma	poč.hodnot	11
					sigma	0.25				
3.	nominální hodnota	1	rozdělení	diskrétní uniformní	levá mez	-5	ořezání	3 - sigma	poč.hodnot	11
					pravá mez	5				
4.	nominální hodnota	1	rozdělení	normální	$\mu$	1	ořezání	3 - sigma	poč.hodnot	11
					sigma	0.3				
5.	nominální hodnota	1	rozdělení	trojúhelníkové	levá mez	0.8	ořezání	3 - sigma	poč.hodnot	11
					pravá mez	1.2				
6.	nominální hodnota	1	rozdělení	lognormální	$\mu$	1	ořezání	3 - sigma	poč.hodnot	11
					sigma	0.21				

Vygenerovat      Zrušit

Obr. 4 Integrovaný panel pro aplikaci metody LHS vyvinutý v [16] a předpokládaný pro užití v HAVAR

### **Profesionální produkt LHS EPITool**

Konečně se zmíníme o jiné alternativní možné cestě vedoucí k získání obecně nabízeného subsystému pro LHS vzorkování. Jedná se o produkt LHS EPITool inzerovaný na internetu. Demonstrační verze však nabízí pouze dva typy rozdělení (uniformní a trojúhelníkové), jak je patrné z obrázku 5. V současné době probíhá jednání s dodavatelem o použitelnosti systému EPITool pro účely programu HAVAR a dalších licenčních podmínkách.

# Latin Hypercube Sampling (EPITool)

## Step 2: Enter names and choose distributions.

Number of variables: 4

Name:

Distribution:  Uniform  Triangular

---

Name:

Distribution:  Uniform  Triangular

---

Name:

Distribution:  Uniform  Triangular

---

Name:

Distribution:  Uniform  Triangular

---

Obr. 5a: EPITool základní panel

# Latin Hypercube Sampling (EPITool)

## Step 3: Enter Numerical Values for Distributions

Number of variables: 4

Name: u1

Uniform: Lower bound:  Upper bound:

Name: u2

Triangular: Lower bound:  Mode:  Upper bound:

Name: u3

Triangular: Lower bound:  Mode:  Upper bound:

Name: u4

Uniform: Lower bound:  Upper bound:

Enter sample size:

Print this page for your records.

Obr. 5b: EPITool následný panel

## 6 STANOVENÍ NÁHODNÝCH CHARAKTERISTIK DÍLČÍCH KOMPONENT MODELU

Programový systém HAVAR je navrhován pro popis šíření kontaminace radionuklidu a pro odhady míry ozáření osob. Pozornost je zaměřena na primární úniky do atmosféry, šíření hydrologickou cestou se zde neuvažuje. Hlavními výstupními veličinami jsou dávky záření v důsledku vnějšího a vnitřního ozáření, které se počítají na základě těchto hlavních řídicích veličin modelu:

- Koncentrace aktivity nuklidů ve vzduchu
- Časový integrál koncentrace aktivity v přízemní vrstvě vzduchu
- Depozice aktivity na zemském povrchu

Všechny tyto tři veličiny jsou výsledkem prvního kroku – modelování advekce a disperze příměsí při jejich unášení v atmosféře s uvažováním mechanismů suchého vypadávání nuklidů a jejich vymývání z vlečky s následnou depozicí aktivity na zemském povrchu. Na jejich základě se pak provádí odhady radiologického zatížení od jednotlivých cest ozáření. Z hlediska odhadu neurčitostí výsledných veličin jsou jejich základní náhodné fluktuace způsobené neurčitostmi atmosférického modelu. Na ně se potom postupně „nabalují“ další efekty způsobené neurčitostmi konverzních faktorů a jiných komponent dosimetrického modelu, dynamických parametrů ingesčního modelu apod. V prvním kroku je tedy třeba začít s analýzou atmosférického modelu (dále ATM).

### *Analýza neurčitostí v modelech šíření radioaktivity v atmosféře*

Mechanismus procesů disperze v atmosféře je natolik složitý, že dosud neexistuje žádný univerzální model pro jeho simulaci. Podle charakteru úlohy (šíření v blízkém okolí zdroje, popis pro střední vzdálenosti, odhady pro velké vzdálenosti od zdroje), dostupnosti dat (hlavně podrobných meteorologických předpovědí), lidských kapacit vývojového týmu a výpočetních možností se přijímají určitá zjednodušení modelu, která sebou přinášejí první zdroj neurčitostí (většinou typ B - kapitola 2). V současné době existují tři alternativní cesty k modelování procesů v atmosféře. Z historického hlediska je nejstarší gaussovský model, který zavádí zjednodušené dílčí poloempirické modely. Je použitelný jen za určitých situací, nicméně může sloužit jako robustní model pro rychlé konservativní odhady. Podrobnější popis poskytuje Lagrangeův trajektoriový model, vyžaduje však podrobnější parametrizaci směšovací vrstvy na základě dostupných meteorologických měření. Nejpodrobnější eulerovské modelování vyžaduje detailní meteorologická data z předpovědních modelů HIRLAM resp. ALADIN. Obecně lze říci, že přesnější modely nemusejí vždy poskytovat lepší výsledky, pokud nemají zajištěn přísun kvalitních vstupních údajů.

Prvním zdrojem nepřesností výsledných odhadů je tedy míra zjednodušení algoritmu popisu problému. V programu HAVAR je užito několik alternativních modelů disperze s různým stupněm zjednodušení založených na gaussovském popisu. Nejvyšším modelem v této hierarchii je hybridní plume-puff model, který je schopen modelovat pohyb segmentu vlečky

(dané superpozicí dílčích obláčků) podle měnících se povětrnostních charakteristik. Celá analýza neurčitostí je v programu HAVAR založena na Gaussově modelu šíření, buď v jeho jednodušší formě přímočaře se šířící vlečky nebo plume-puff modelu. Lze se domnívat, že analýza neurčitostí (UA – Uncertainty Analysis) prováděná v tomto prostředí poskytne konzistentní a obecně platné představy o šíření neurčitostí vstupů modelem.

Za základ k rešerši metodiky UA disperzních modelů byly považovány následující prameny:

1. UA programových systémů COSYMA (UFOMOD) a MACCS - [3, 4, 9, 15, 18]
2. UA modelu CALPUFF s ohledem na meteorologické vstupy - [17]
3. UA NRPB kódu MARC-2A - [2]
4. UA atmosférického disperzního kódu NPK-PUFF (Nizozemsko) -[19]
5. Kód OSCAAR -[5] : japonský přístup k UA

Analýza neurčitostí prováděná jednotlivými týmy vychází z jejich subjektivních odhadů příslušné relevantní grupy vstupních náhodných parametrů a mezi jednotlivými studii se liší. V dalším textu se zmíníme o některých významnějších studiích, pro vlastní cíle programu HAVAR pro případ pravděpodobnostních odhadů je proveden přehled konkrétních parametrů se zvoleným konkrétním rozdělením a je zařazen do přílohy 2 (grupa neurčitostí vstupních parametrů pro atmosférický a depoziční modul) a do přílohy 3 (parametry ingesčního modelu).

Do analýzy šíření radionuklidů v atmosféře primárně vstupují základní informace zahrnující [17] :

1. Zdrojový člen úniku (poloha, časová dynamika, složení a intenzita úniku, efekty na výstupu ovlivňující proudění)
2. Meteorologické charakteristiky
3. Údaje o charakteristikách zemského povrchu v okolí zdroje znečištění (výškopis, typ zemského povrchu, drsnost povrchu)

Výsledky modelování disperze a depozice jsou závislé též na neurčitostech jmenovaných základních dat, které přispívají k neurčitostem dalšího šíření směrem k toxikologickému modulu a modulu odhadů potenciálního ozáření.

Práce [20] shrnuje charakteristiky disperzních modelů vlečky s důrazem na:

- Fluktuace příčného profilu koncentrace
- Neurčitosti disperzních parametrů
- Neurčitosti určování vzhledu vlečky
- Nepřesnosti stanovení (měření) střední advekční rychlosti a jejího směru

Práce doporučuje považovat rozdělení fluktuací rychlosti a směru větru za normálně rozdělené, zatímco lognormální rozdělení může být použito pro rozdělení chyb pro ostatní parametry.

Přesnost předpovědi (tj. výsledných výpočtů) ovlivňují svými neurčitostmi následující vstupní parametry a předpoklady modelu. Např. v [21] se uvádějí oblasti:

- Stanovování horizontálních a vertikálních disperzních koeficientů
- Určování vznosu mraku a efektivní výšky úniku
- Metody stanovení kategorií stability atmosféry
- Přesnost stanovení rychlosti větru
- Stanovení profilu rychlosti větru v závislosti na výšce
- Stanovení směšovací výšky
- Doba průměrování přízemní objemové aktivity (zda-li jsou to např. 10-ti minutové, 30-ti minutové nebo hodinové průměry), tedy zahrnutí efektu fluktuací vlečky kolem základního směru (plume meandering).

Poučným příkladem pro volbu strategie UA podává práce [19] v tom smyslu, že upřednostňuje pečlivý výběr několika nejdůležitějších parametrů před maximalistickým přístupem vlekoucím sebou všechny myslitelné parametry. Při UA dánského lagrangeovského modelu NPK-PUFF pro modelování na dlouhé vzdálenosti jsou uvažovány:

<i>Vstupní parametr</i>	<i>Střední hodnota</i>	<i>Rozsah resp. její pdf</i>
Drsnost povrchu (m)	0.25	0.001 – 3 (trojúhelníkové)
Směšovací výška (frakce)	0.65	0.3 – 1 (uniformní)
Efektivní výška (m) (nízký zdroj)	15	10 – 20 m (uniformní)
Efektivní výška (m) (vysoký zdroj)	400	200 – 600 m (uniformní)
Vertikální disperze (frakce)	1.25	0.5 – 2 (uniformní)
Počáteční horiz. disp. (m)	130	10 - 250 (uniformní)
Lagrang. čas. škála (min)	90	1 - 180 (uniformní)
Odpor povrchu I131 (s.m <sup>-1</sup> )	120	60 – 200 (trojúhelníkové)
Konstanta vymývání deštěm (s <sup>-1</sup> )	5.8E-5	1E-5 až 1E-4 (trojúhelníkové)

Obdobný realistický přístup je uveden v práci [3], kde jsou uvažovány fluktuace parametrů:

- $\sigma_{y0}$  ,  $\sigma_{z0}$  : počáteční horizontální a vertikální rozšíření vlečky v důsledku vlivu blízkostojících objektů
- výšky směšovací vrstvy v závislosti na kategoriích stability
- $\sigma_y(\text{stab})$  ,  $\sigma_z(\text{stab})$  : horizontální a vertikální difúzní koeficienty v závislosti na kategoriích stability
- $v_g$  : rychlost suché depozice s rozlišením pro aerosoly a elementární formu jódu
- $\Lambda$  : koeficient vymývání s rozlišením pro aerosoly a elementární formu jódu



Obdobný výběr poskytuje kód OSCAAR [5], který náhodný charakter přisuzuje i multiplikačnímu koeficientu (frakci) ve výpočtu vertikálního profilu větru. Významným vodítkem pro konstrukci grupy vstupních náhodných parametrů je kód COSYMA [11], který kromě percentilů rozdělení udává i základní informace o skutečných vzájemných korelacích mezi jednotlivými vstupními parametry.

### **Konkrétní model atmosférické disperze s omezeným počtem vstupních náhodných parametrů.**

Pro demonstraci pravděpodobnostního přístupu se v první fázi zaměříme na omezenou grupu čtyř vstupních parametrů, pro které lze nalézt různá doporučení na náhodný charakter těchto veličin.

Úvodní úvahy budou vedeny pro přímočarý Gaussův model šíření vlečky se čtyřmi vybranými náhodnými parametry  $c_1, c_2, c_3, c_4$  specificky ovlivňujícími tvar gaussovské plochy nad terénem:

Intensita úniku aktivity ze zdroje znečištění  $A = c_1 * A_{nom}$

Horizontální disperze vlečky  $\sigma_y(x) = c_2 * \sigma_y(x)_{nom}$

Neurčitost zadaného směru větru  $\phi = c_3 * \phi_{nom}$

Rychlost suché depozice  $v_g = c_4 * v_{g,nom}$

Dále předpokládejme, že parametry  $c_1, c_2, c_3$  a  $c_4$  jsou bezrozměrné a jejich náhodné charakteristiky budou odhadnuty dále na základě expertních studií z literatury. Mají charakter standardizovaných proměnných popsáných vztahem (2). Z geometrického hlediska lze charakterizovat ovlivnění tvaru gaussovské plochy nad terénem jednotlivými parametry následovně:

$c_1$  : posun plochy výsledků modelu jako celku ve vertikálním směru (celkové snížení resp. zvýšení hodnot v konstantním poměru  $c_1$ )

$c_2$  : určuje tvar disperze v horizontálním směru podle závislosti  $EXP(-y^2/(2*\sigma_y(x)^2)) = EXP(-y^2/(2*(c_2 * \sigma_y(x)_{nom})^2))$ . Ovlivňuje tedy strmost rozdělení kolem osy vlečky v příčném směru ( názorně představuje zmáčknutí resp. rozpliznutí kolem osy šíření vlečky)

$c_3$  : faktor představující otočení získaných výsledků modelování jako celku kolem počátku (zdroje úniku) o dodatečnou náhodnou diferenci úhlu

$c_4$  : ovlivňuje intenzitu depozice aktivity na terénu a dále míru ochuzování aktivity ve vlečce postupující nad terénem (neboli ovlivňuje tvar průběhu závislosti modelovaných veličin ve směru šíření vlečky  $x$ ).

Pro definici náhodných charakteristik výběr z literatury poskytuje pro  $C_1, C_2, C_3, C_4$  následující údaje:

[2] MARC:

- neuvažuje neurčitosti zdrojového členu

- velikost aerosolů AMAD=1.0  $\mu\text{m}$ , fluktuační se promítanou do neurčitosti suché depozice VG
- neurčitost v horizontální disperzi  $\sigma_y$  = neurčitosti fluktuační směru větru vztažená k periodě desítky minut  $\sigma_{yw}$  (což je vlastně  $\sigma_\theta$ ). Neurčitost turbulentní fluktuační složky v měřítku několika málo minut  $\sigma_{yt}$  je plně korelovaná se  $\sigma_z$  (toto je rozlišováno pro každou kategorii zvlášť)

Číselné hodnoty:

pro  $\sigma_\theta$  : (min,str,max) = (1.8e-3, 1.0e-2, 5.8e-2), Log-normal, bezrozměrná

pro  $\sigma_z$  : (min,str,max) = (35, 43, 55), Triangular, v (m), kat D v 1 km

- pro VG:

elemental: (min,str,max) = (6.2e-4, 1.0e-2, 1.6e-1), Log-normal, m/s

aerosol: (min,str,max) = (9.0e-6, 5.5e-4, 3.4e-2), Log-normal, m/s

### [3] UFOMOD:

Podstatnou část variability v koncentraci aktivity způsobují:

- výška směšovací vrstvy : (min,str,max) = (0.5, 1, 1.5) –100 % rozsahu (např. pro D=600 m ... je pak zřejmě 300m až 900 m), Triangular
- neurčitost ve VG:

elementární: (min,str,max) = (1/3, 1, 3), nom=1e-2 m/s), Log-normal,

aerosol: (min,str,max) = (1/5.5, 1, 5.5), nom=1e-2 m/s , Log-normal,

Obě rozdělení jsou lognormální omezené na min=0.1% quantil, str=50% quantil, max=99.9% quantil

- horizontální disperze  $\sigma_y$  : rozlišení podle kategorií stability, bezrozměrná frakce má trojúhelníkové rozdělení <min-max>

Pro takto definovanou úlohu byla vypracována první jednoduchá verze pravděpodobnostního programu HAVAR. Pro popsání LHS generátor bylo spočteno celkem 1000 náhodných realizací výstupních veličin. Postup je podrobněji popsán v práci [1].

### Neurčitosti v modelu potravních řetězců

Úkolem tohoto odstavce je nalézt relevantní reference na grupu vstupních parametrů inženýrského modelu. Výchozím zdrojem informací jsou práce:

- [5, 26] : OSCAAR kód
- [12] : GENII kód
- [3] : UFOMOD kód
- [18] : informace k pravděpodobnostnímu přístupu v kódu COSYMA

- [27] : Popis dynamického modelu ingesce ECOSYS
- [28] : Popis dynamického modelu ingesce FARMLAND

Hlavním zdrojem pak jsou práce:

- [10]: Analýza neurčitostí v důsledku variability parametrů v modelu potravních řetězců a ve výpočtech dávek z ingesce pro radioekologický model ECOSYS, který je základem podobných kalkulací i v systému RODOS
- [2] : Analýza neurčitostí predikce následků jaderných nehod s užitím NRPB kódu MARC-2A
- [22]: Studie citlivosti modelu ECOSYS-87 v důsledku variability parametrů v modelu potravních řetězců
- [14]: Návrh strategie pro UA modelu potravních řetězců systému RODOS.

*Poznámka ke koncepci v systému RODOS: Je navrhována LHS procedura náhodných výběrů z množiny vstupních parametrů. V prvním kroku je definován rozsah vstupních parametrů ingesčního modelu a dále náhodné charakteristiky z předchozího modelování atmosférické disperze a depozice, které vstupují do ingesčního modelování též jako vstupní hodnoty. Z této množiny se provede nagenování celkem K realizací vstupního náhodného vektoru s možností respektovat vzájemné korelace. Tyto hodnoty se umísťují do externího souboru, použitého v dalším kroku. Ve druhém kroku je prováděn Monte Carlo výpočet, kdy je model K-krát počítán vždy znovu pro konkrétní realizaci vstupů. Ve třetím kroku jsou výsledky formulovány v pravděpodobnostních termínech, např.:*

- *určení frekvenčních funkcí důležitých výstupů (ingesční dávky, aktivita v potravinách)*
- *určení kvantilů rozdělení a intervalů spolehlivosti*

*Výše jmenovaná fakta musí vést k opatrnosti, aby velký rozměr úlohy neznehodnotil cíl výpočtů. Je třeba si uvědomit, že mnohonásobné Monte Carlo modelování začíná po volbě příslušného scénáře. Ten je vyjádřen specificky deterministicky definovanými veličinami, jako jsou:*

- *juliánský den spadu v roce*
- *grupa radionuklidů*
- *konkrétní meteorologická situace a případný výskyt srážek*
- *neurčitosti vstupující z atmosférického modelování*

*V případě snahy zahrnout do výpočtů i variabilitu scénářů pak objem výpočtů mimořádně poroste a i z praktického hlediska není takový postup přínosný, vede ke zkomplikování celé situace a potíží při interpretaci výsledků.*

-----

Na základě citované literatury je proveden výběr náhodných parametrů ingesčního modelu, který je uveden v přílohách 3. Tato množina bude dále zúžena na základě plánované studie senzitivity a seřazení parametrů podle jejich efektu na sledované výstupy. Při shromažďování podkladů pro grupy neurčitostí jednotlivých částí ingesčního modelu byla v konečné fázi zaměřena pozornost na dva nejvýznamnější dynamické modely používané v Evropě, a to :

1. Model ECOSYS [27] - dynamický model vyvinutý v GSF (Německo) a laděný původně na podmínky jižního Německa, které pokládáme za blízké podmínkám středoevropským.
2. Model FARMLAND [28] - dynamický model vyvinutý v NRPB (Anglie) lokalizovaný původně pro podmínky Velké Británie, později byl rozšířen pro obecnější použití.

Oba modely jsou dnes integrovány do významných programových systémů COSYMA a RODOS pro odhady radiologických dopadů radioaktivních úniků, kde představují dvě základní volby pro cestu ingesce.

Významný faktem je, že oba modely vstoupily do procesu analýzy neurčitostí, kdy spolu s příslušnou předřazenou částí pro atmosférický a depoziční submodel vytvořily nástroj pro kvantitativní odhady šíření neurčitostí vstupních parametrů modelem směrem ke sledovaným cílovým veličinám. Významným zdrojem informací o novém pravděpodobnostním přístupu se tak staly provedené procedury analýzy neurčitostí s užitím řetězců kódů:

1. UFOMOD (viz [3, 4]) → ECOSYS
2. MARC-2A (viz [2]) → FARMLAND

Další důležité výpočty byly provedeny s užitím kódu COSYMA (u kterého atmosférická a depoziční část vychází z kódu UFOMOD) v [23] a pomocí amerického kódu MACCS [7, 8], kdy byly alternativně použity modely ECOSYS nebo FARMLAND. Obdobnou volbu poskytuje i systém RODOS.

Problematikou redukce počtu neurčitých vstupních parametrů pro účely nově vyvíjeného systému HAVAR se zabývá práce [1]. V této práci jsou shromážděny na základě citované literatury konkrétní údaje ke skupě neurčitostí vstupních parametrů ingesčního modelu.

## 7 LITERATURA

- [1] Pecha P.: Návrh metodiky generování pravděpodobnostních charakteristik cílových veličin v modelech šíření radionuklidů životním prostředím. *Dokumentace k etapě E 01 g) projektu 6/2003*, červen 2004.
- [2] Jones J.A., Mansfield P. A., Crick M. J. : Uncertainty Analysis of the Predicted Consequences of Nuclear Accidents Using the NRPB Code MARC-2A. NRPB-R274, 1995.
- [3] Fischer F., Ehrhardt J., Hasemann I. : Uncertainty and Sensitivity Analysis of the Complete Program System UFOMOD and Selected Submodels. KfK 4627, 1990.
- [4] Fischer F., Ehrhardt J., Raicevic J. : Analysis of uncertainties Caused by the Atmospheric Dispersion Model in Accident Consequence Assessments with UFOMOD. KfK 4262, 1988.
- [5] Homma T., Inoue Y., Tomita K. : OSCAAR Calculations for the Hanford Dose Reconstruction Scenario of BIOMASS Theme 2. JAERI – Research 2000-049, 2000.
- [6] Evaluating the Reliability of Predictions Made Using Environmental Transfer Models. Safety series, No. 100, IAEA, 1989.
- [7] Goossens L., Harper F.T. : Joint EC/USNRC Expert Judgement Driven Radiological Protection Uncertainty Analysis. J. Radiolog. Prot., Vol 18, 1998
- [8] Young M. : Joint EC/USNRC Uncertainty Study: Dispersion and Deposition Panel. SANDIA NL, (1994).
- [9] Jones J.A.(NRPB), Goossens L.(TUD), Hasemann I., Fischer F., Ehrhardt J.(FZK) : Uncertainty Analysis on COSYMA – Results for Dispersion and Deposition Module Analysis. Study under Contract No.: FI4P-CT95-0006
- [10] Müller H., Friedland W., Pröhl G., Gardner R.H. : Uncertainty in the Ingestion Dose Calculations. Rad. Prot. Dos., Vol. 50(1993)
- [11] Jones J.A.(NRPB), Goossens L.(TUD), Hasemann I., Fischer F., Ehrhardt J.(FZK) : Uncertainty Analysis on COSYMA – Results of the Dispersion and Deposition Module Analysis
- [12] Napier B.A., Strenge D.L. at al. : GENII Version 2 - Software Design Document. Under USEPA Contract DE-AC06-76RLO 1830, Nov. 2002
- [13] Homma T., Satelli A. : LISA – Package User Guide, Preparation of Input Sample for Monte Carlo Simulations. EUR 13922 EN (1992)
- [14] Bleher M., Gering F., Hübner S., Müller H. : Data Assimilation and Uncertainty in RODOS FCM Assessment. RODOS (WG3)-TN(97), 1997
- [15] Fischer F. : Procedures for Uncertainty Analysis of UFOMOD – A User Guide. KfK 4626 (1990)
- [16] Housa L. (školitel Pecha P.) : Pravděpodobnostní přístup posuzování závažnosti radioaktivních úniků do atmosféry (květen 2004).
- [17] Chang J. C : Uncertainty and Sensitivity of Dispersion Model Results to Meteorological inputs: Two Case Studies. In Qualitative Methods for Current nvironmental Issues (Springer, 2002), ISBN 1-85233-294-8

- [18] Jones J.A., Brown J.,(NRPB), Goossens L.(TUD), Hasemann I., Fischer F., Ehrhardt J.(FZK) : Uncertainty Analysis on COSYMA, 3rd COSYMA-MACCS Meeting, Portorož, 1996.
- [19] Kok Y. S., Eleveld H. : Sensitivity and Uncertainty Analysis of the Atmospheric Dispersion Model NPK-PUFF. HARMON9 - Int. Conf. On Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes, Vol.1, Garmisch-Partenkirchen, 1-4 June, 2004.
- [20] Irwin J.S., Hanna S.R. : Characterizing Uncertainty in Plume Dispersion Models. HARMON9 - Int. Conf. On Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes, Vol.1, Garmisch-Partenkirchen, 1-4 June, 2004.
- [21] Beychok M.R. : Error Propagation in Air Dispersion Modeling, Newport Beach, California, USA, zdroj informací na serveru GOOGLE.
- [22] Hinton T.G. : Sensitivity Analysis of ECOSYS-87 : An Emphasis on the Ingestion Pathway as a Function of Radionuclide and a Type of Deposition. Health Physics, Vol. 66, No.5, 1994.
- [23] Jones J.A., Brown J.,(NRPB), Goossens L., Kraan B., Cooke R., (TUD), Ehrhardt J., Hasemann I., Fischer F., (FZK) : Uncertainty Analysis on the Probabilistic Accident Consequence Code COSYMA. Radiological Prot. Bulletin No. 232, Dec. 2001.
- [24] Švanda J.: Analýza neurčitosti vstupních parametrů a použitých fyzikálních modelů s cílem zvýšení spolehlivosti předpovědí. Závěrečná zpráva k etapě E 01 f) projektu 6/2003, červen 2004
- [25] Mueck K., Suda M., Gerzabek M., Kunsch B.: Ingestion Dose Response to the Deposition Date in the First Year after Radionuclide Deposition. Rad. Prot. Dosimetry, vol. 42, No. 2-4(1992).
- [26] Homma T., Matsunaga T. : OSCAAR Calculations for the Input Dose Reconstruction Scenario of BIOMASS Theme 2. JAERI – Research 2000-059, 2001.
- [27] Müller H., Pröhl G. : ECOSYS-87: A Dynamic Model for Assessing Radiological Consequences of Nuclear Accidents. Health Physics, Vol. 64, No. 3, March 1993
- [28] Brown J., Simmonds J. R. : FARMLAND: A Dynamic Model for the Transfer of Radionuclides through Terrestrial Foodchains. NRPB, NRPB-R273, 1995.
- [29] Brown J. : FARMLAND: Validation and Verification Studies on the NRPB Dynamic Terrestrial Foodchain Model, NRPB, NRPB-M523, 1995.

## 8 PŘÍLOHA 1: METODIKA LHS POUŽITÁ V PRÁCI [16]

Metoda při generování uvažuje k-tici vstupních náhodných veličin  $X_1, \dots, X_k$ , podobně jako v předchozí metodě. Úkolem je vygenerovat matici  $\mathbf{A}^{N,K}$ .


Myšlenka je následující :

Rozdělit rozsah každé vstupní náhodné veličiny  $(a_i, b_i)$  na  $N$  nepřekrývajících se intervalů  $\gamma_i^j$ , přičemž příslušné intervalové pravděpodobnosti budou stejné, tj.

$$P(X_j \in \gamma_i^j) = P(X_j \in \gamma_l^j); \forall i, l \in \hat{N}, \forall j \in \hat{K},$$

kde  $\gamma_i^j$  je  $i$ -tý interval příslušející náhodné veličině  $X_j$ , a navíc  $P(X_j \in \gamma_i^j) = \frac{1}{N}$ .

Toto rozdělení znázorňuje následující obrázek :



Tím jsme prostor

$$\tau = \prod_{j=1}^K (a_j, b_j) \subseteq R^K$$

rozdělili na  $N^K$  částí (buněk)

$$\gamma_{i_1}^1 \times \gamma_{i_2}^2 \times \dots \times \gamma_{i_K}^K,$$

kde  $(i_1, \dots, i_K)$  je libovolná variace (s opakováním) čísel  $1, 2, \dots, N$ . Každá z těchto buněk je tedy jednoznačně identifikována uspořádanou k-ticí  $(i_1, \dots, i_K)$ . Pak si ze všech těchto  $N^K$  buněk

vybereme právě N buněk, každá tato buňka je identifikována čísly  $b_1, \dots, b_K$ , získali jsme tedy matici

$$\mathbf{B}^{N,K} = \begin{pmatrix} b_{11} & \dots & b_{1K} \\ \vdots & \dots & \vdots \\ b_{N1} & \dots & b_{NK} \end{pmatrix}.$$

Těchto N buněk avšak vybereme tak, aby v každém sloupci matice  $\mathbf{B}^{N,K}$  byla permutace čísel  $1..N$ . Nakonec vytvoříme hledanou matici :

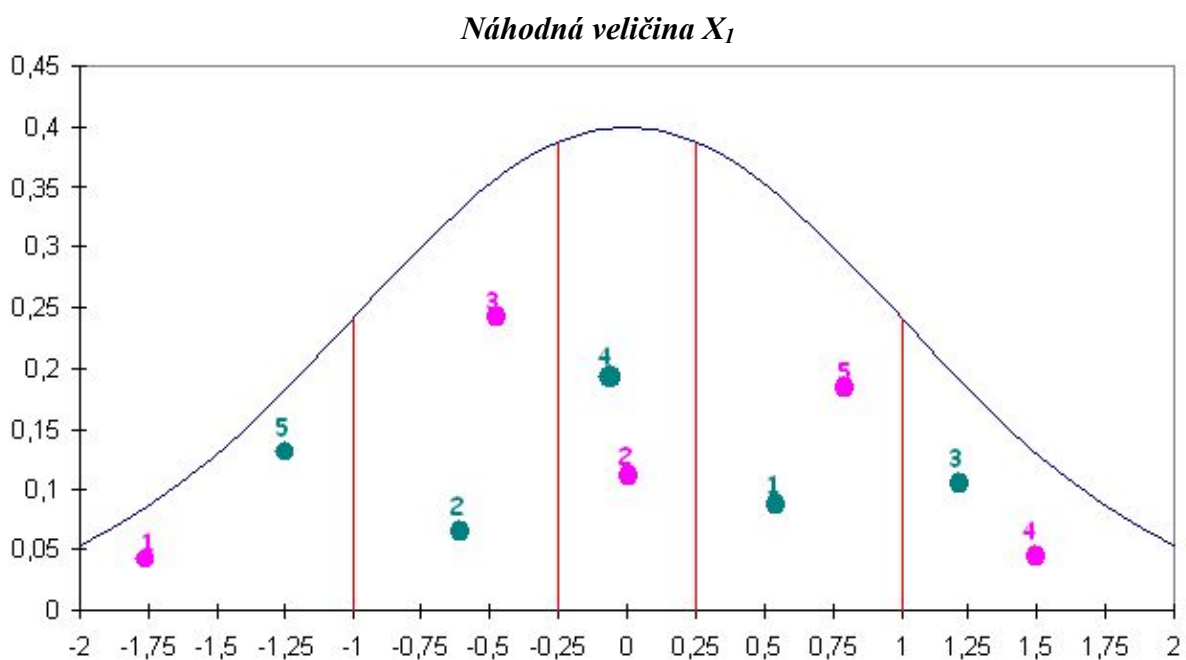
$$\mathbf{A}^{N,K} = (a_{ij})_{\substack{i \in \hat{N} \\ j \in \hat{K}}}$$

$a_{ij}$  je náhodně vybrané číslo v dílčím intervalu  $\gamma_{b_j}^j$ . Tato matice se v anglické literatuře ([5], [8]) označuje jako *Latin hypercube sample of size N*, neboli LH vzorek velikosti N.

Touto volbou (sloupec=permutace  $1..N$ ) zajistíme, že každý dílčí interval  $\gamma_i^j$  každé náhodné veličiny bude použit právě jednou. Tato metoda tedy prozkoumává celý rozsah každé náhodné veličiny. Tím se pak podle [8] dosáhne při generování nestranného odhadu střední hodnoty při nižším N, tj. počtu cyklů a tato metoda je tedy mnohem efektivnější.


*Příklad :*

$j=2, N=5$ , tj. necht' jsou dány 2 náhodné veličiny  $X_1$  a  $X_2$  a necht' známe jejich distribuční funkce (takto to budeme v praxi předpokládat vždy). Dále rozdělíme rozsah každé náhodné veličiny podle schématu (viz výše) a v každém tomto intervalu zvolíme náhodně jednu hodnotu, přičemž opět respektujeme omezení popsána výše. Zde jsou dva možné výsledky tohoto procesu (první fialově, druhý zeleně):

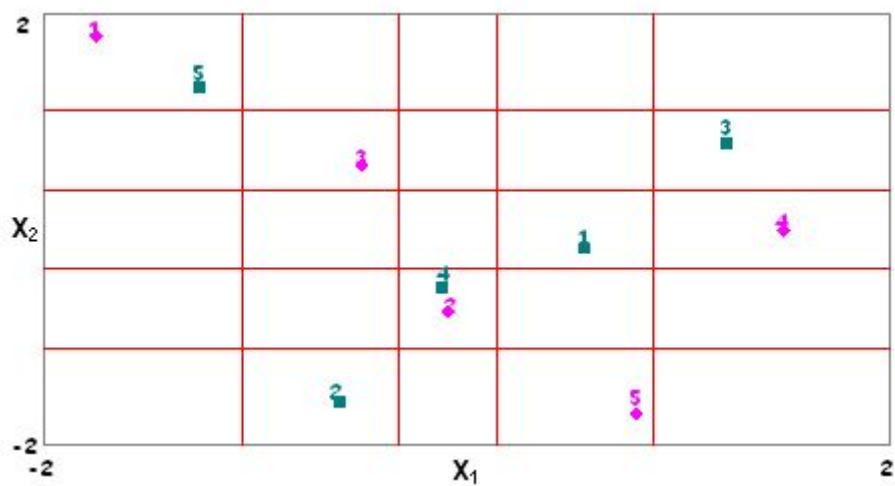




### Náhodná veličina $X_2$



*Síť (rozdělení prostoru viz výše na  $N^K=5^2=25$  buněk) i s jednotlivými vygenerovanými vzorky by potom vypadala zhruba takto:*



## Rozdělení rozsahu každé náhodné veličiny na N intervalů

Nyní si podrobněji popíšeme postup, jakým rozdělíme rozsah každé náhodné veličiny na N intervalů o čemž hovoří metoda LHS. Vyjděme opět ze vztahu pro intervalovou pravděpodobnost :

$$\text{Ozn. } \gamma_i^j = (c_i^j, d_i^j), \text{ platí tedy, že } a_j = c_1^j, b_j = d_N^j$$
$$P(X_j \in \gamma_i^j) = P(c_i^j \leq X_j \leq d_i^j) = \int_{c_i^j}^{d_i^j} f_{X_j}(x) dx = \frac{1}{N}$$

Poslední rovnost jsme již vysvětlili výše. Navíc jsme předpokládali, že veličiny  $X_j$  jsou spojité pro  $\forall j \in \hat{K}$ , tudíž je neostrá nerovnost  $c_i^j \leq X_j$  oprávněná. (neboť pravděpodobnostní míra jednoho bodu je nulová - viz [4]).

Nyní známe hodnotu  $c_1^j = a_j$  (levá mez rozsahu náhodné veličiny  $X_j$ ) a potřebujeme za použití výše uvedené integrální rovnice spočítat všechna  $d_i^j$  pro  $\forall i \in \hat{N}, \forall j \in \hat{K}$ .

Pro použití implementace tohoto postupu na osobním počítači byla v této práci užitá následující aproximace (integrální součet) :

Známe  $c_i^j, N, f_{X_j}(x)$ , chceme spočítat  $d_i^j$ . Algoritmus :

$$d_i^j = c_i^j; \text{ suma}=0;$$

dokud je suma  $< \frac{1}{N}$  pak proved' toto :

$$\text{suma} = \text{suma} + f_{X_j}(d_i^j) * \text{DELTA}(N, f_{X_j});$$

$$d_i^j = d_i^j + \text{DELTA}(N, f_{X_j});$$

Úkolem je již jen určit hodnotu  $\text{DELTA}(N, f_{X_j})$ , aby byla přesnost tohoto algoritmu dostačující. Tato hodnota je závislá na N a na hustotě pravděpodobnosti příslušné náhodné veličiny (např. na parametru  $\sigma$  normálního rozdělení).

Pozn.: spojité hustoty pravděpodobnosti často mívají za svůj rozsah celý obor reálných čísel, kde platí (např. pro normální rozdělení), že :  $\lim_{x \rightarrow +\infty} f_{X_j}(x) = \lim_{x \rightarrow -\infty} f_{X_j}(x) = 0$ . Na osobním počítači je ovšem tato přesnost značně omezená a tak se nahradí daný neomezený rozsah  $(a_j, b_j)$  jiným omezeným rozsahem  $(a'_j, b'_j)$  tak, aby funkční hodnoty hustoty náhodné veličiny  $X_j$  v těchto nových mezích byly „rozumně“ vyčíslitelné na PC.

## 9 PŘÍLOHA 2: VÝBĚR NEURČITOSTÍ VSTUPNÍCH PARAMETRŮ ATMOSFÉRICKÉHO A DEPOZIČNÍHO MODELU

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>standardní odchylka <math>\sigma</math></i>	<i>90 % percentil</i>	<i>max</i>	<i>typ rozdělení</i>
$\sigma_z$ kat.A pro 1. km	m	1.4E+2	1.7E+2	1.8E+2		2.8E+2	3.4E+2	trojúhelníkové
$\sigma_z$ kat.B pro 1. km	m	8.2E+1	9.1E+1	9.6E+1		1.2E+2	1.4E+2	trojúhelníkové
$\sigma_z$ kat.C pro 1. km	m	5.5E+1	6.1E+1	6.8E+1		7.4E+1	8.2E+1	trojúhelníkové
$\sigma_z$ kat.D pro 1. km	m	3.5E+1	3.9E+1	4.3E+1		5.1E+1	5.5E+1	trojúhelníkové
$\sigma_z$ kat.E pro 1. km	m	2.1E+1	2.5E+1	2.8E+1		3.4E+1	3.5E+1	trojúhelníkové
$\sigma_z$ kat.F pro 1. km	m	1.1E+1	1.3E+1	1.5E+1		1.9E+1	2.1E+1	trojúhelníkové
$\sigma_y$ – horizontální flukt. Větru	-	1.8E-3	5.0E-3	1.0E-2		2.1E-2	5.8E-2	Log-normal
poč. vliv budov na $\sigma_y$	-	5.0E-1	7.2E-1	1.0E+0		1.3E+0	1.5E+0	trojúhelníkové
poč. vliv budov na $\sigma_z$	-	5.0E-1	7.2E-1	1.0E+0		1.3E+0	1.5E+0	trojúhelníkové
$v_g$ pro aerosoly	m.s <sup>-1</sup>	9.0E-6	1.0E-4	5.5E-4		3.0E-3	3.4E-2	lognormální
$v_g$ pro elem. jód	m.s <sup>-1</sup>	6.2E-4	3.2E-3	1.0E-2		3.2E-2	1.6E-1	lognormální
exponent pro vymývání	-	5.0E-1	5.5E-1	7.5E-1		9.5E-1	1.0E+0	rovnoměrné
korekce na směš. výšku	-	5.0E-1	7.2E-1	1.0E-0		1.35E-0	1.5E+0	trojúhelníkové

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>standardní odchylka <math>\sigma</math></i>	<i>90 % percentil</i>	<i>max</i>	<i>typ rozdělení</i>
drsnot zem. povrchu	m	0.001		0.25			3	trojúhelníkové
eff. výška (nízký zdroj) ~15m		10					20	rovnoměrné
eff. výška (vysoký zdroj) ~400m		200					600	rovnoměrné
korekce na profil větru (exp.)	-			1.0E-0	0.15			normální N(1, 0.15)

## 10 PŘÍLOHA 3: VÝBĚR NEURČITOSTÍ VSTUPNÍCH PARAMETRŮ MODELU POTRAVNÍCH ŘETĚZCŮ A VÝPOČTU DÁVEK

### Příloha 3a: Nejdůležitější parametry vybrané na základě studií citlivosti v [10] pro ingesční model ECOSYS

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>standardní odchylka <math>\sigma</math></i>	<i>90 % percentil</i>	<i>max</i>	<i>typ rozdělení</i>
rychlost suché depozice		0.001		1.00	0.5		2.00	normální
intercepční frakce		0.25		1.00	0.5		2.00	normální
translokační faktory pro Cs		0.4		1.00 **			2.50	log-trojúhelníkové
přenosový faktor Cs z půdy do rostliny		0.4					2.50	log-uniformní
přenosový faktor Sr z půdy do rostliny		0.3					3.00	log-uniformní
faktor resuspenze		0.4					2.50	log-uniformní
rychlost odstranění Sr (vylouhování)		0.5					2.00	log-uniformní
poločas smývání	den	15		25 **			35	trojúhelníkové
hmotnost půdy v kořenové zóně	kg/m <sup>2</sup>	300.00					400.00	trojúhelníkové
přenosový		0.66					3.00	uniformní

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>standardní odchylka <math>\sigma</math></i>	<i>90 % percentil</i>	<i>max</i>	<i>typ rozdělení</i>
přenosový faktor Cs do mléka								
přenosový faktor Sr do mléka		0.5					1.25	uniformní
přenosový faktor I do mléka		0.66					3.00	uniformní
přenosový faktor Cs do masa		0.5					1.5	uniformní
výnos listové zeleniny	kg/m <sup>2</sup>							trojúhelníkové
datum sklizně pšenice		15. červenec		1. srpen			15. srpen	trojúhelníkové
faktor zpracování listové zeleniny		0.6					1.00	uniformní
faktor zpracování mouky		0.4					0.60	uniformní
faktor spotřeby zeleniny		0.7		1.00 **			1.30	trojúhelníkové
krmné dávky krav		0.85					1.15	uniformní

***Příloha 3b: Výběr parametrů v analýze neurčitosti provedené v [5] s užitím kódu OSCAAR***

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>střední odchylka <math>\mu</math></i>	<i>standardní odchylka <math>\sigma</math></i>	<i>max</i>	<i>typ rozdělení</i>
hmotnost intercepční frakce pro trávu na pastvinách	m <sup>2</sup> /kg-dw			2.0	0.26	0.19		log-normální
poločas smývání	den			10.4	1.0	0.13		log-normální
časové období, během něhož je vegetace vystavena kontaminaci	den			30	-	-		konstantní
obsah vody v trávě na pastvinách	-			0.1 – 0.75				uniformní
denní příjem dojnice	kg-dw/den			9.0	9.0	2.3		normální
vyložená frakce denního příjmu radiojódů na litr mléka	1/litr			0.0091	-2.04	0.24		log-normální
doba mezi dojením a spotřebou mléka	den			2.0	2.0	0.86		normální
spotřeba mléka: testované osoby	litr/den			0.315	-0.65	0.36		log-normální
muž				0.377	-0.57	0.36		
žena				0.260	-0.73	0.36		

<i>Vstupní parametr</i>	<i>jednotka</i>	<i>min</i>	<i>10 % percentil</i>	<i>střední hodnota</i>	<i>střední odchylka <math>\mu</math></i>	<i>standardní odchylka <math>\sigma</math></i>	<i>max</i>	<i>typ rozdělení</i>
dítě				0.497	-0.36	0.21		
farma - hoch				4.0				konstantní
farma - děvče				1.0				konstantní
zpoždění od sklizně listové zeleniny do konzumace lidmi	den			5.0	-	-		konstantní
poměr spotřeby listové zeleniny: testované osoby	kg-fw/den			0.049	-	-		konstantní
muž				0.047	-	-		
žena				0.050	-	-		
dítě				0.0072	-	-		

dw ... dry weight (suchá hmotnost)

fw ... fresh weight (hmotnost čerstvé rostliny)



**Příloha 3c: Výběr parametrů v analýze neurčitostí provedené v [2] s užitím kódu MARC-2A**