

# DISCOVERY OF WIRELESS SENSOR NETWORK TOPOLOGY USING GENETIC ALGORITHMS

Štěpán Dalecký

Bachelor Degree Programme (3), FIT BUT

E-mail: xdalec01@stud.fit.vutbr.cz

Supervised by: František Zbořil


E-mail: zboiril@fit.vutbr.cz

**Abstract:** Paper deals with discovery of wireless sensor network topology. Genetic algorithm has been chosen for this purpose. Input information is only signal strength between some pairs of devices. Design of genetic algorithm has significant impact on usability but with good design proposed model works well.

**Keywords:** wireless network, network topology, genetic algorithms, artificial intelligence, WSageNt

## 1. ÚVOD

Bezdrátovou senzorovou síť si můžeme představit jako několik zařízení, která jsou rozmístěna například v lese a sledují pohyby osob. Jednotlivá zařízení mohou bezdrátově komunikovat s okolím. Se vzdálenějšími zařízeními pak komunikují pomocí těch bližších. Například pro směrování dat mezi zařízeními je vhodné mít možnost zjistit, jak jsou senzory rozmístěny. Jediná informace, kterou nám k tomu senzory poskytují, je síla signálu mezi jednotlivými dvojicemi. Na síť lze též nahlížet jako na ohodnocený graf viz. Obrázek 1 (pro přehlednost bez ohodnocení hran), kde senzory jsou uzly a signál mezi nimi je vyznačen hranami. Síla signálu je potom ohodnocení hrany. Hlavním cílem této práce je navrhnout genetický algoritmus, který na základě sil signálů převedených na vzdálenost určí pozici senzorů, kterou lze následně použít pro vykreslení jejich mapy.



Obrázek 1: Síť jako graf.

## 2. PŘEVOD SÍLY SIGNÁLU NA VZDÁLENOST

Jelikož jediným zdrojem dat je síla signálu naměřená mezi jednotlivými senzory, je třeba pro další postup tuto sílu signálu převést na vzdálenost a tu poté využít pro hodnocení kvality řešení v genetickém algoritmu. To můžeme udělat měřením a aproximací této závislosti funkcí. Pokud je naměřený signál menší než hranice určená experimentálně, tak tento signál vůbec nebudeme uvažovat, čímž zabráníme výrazným chybám způsobených tím, že dané dva uzly jsou od sebe daleko, a tudíž je měření signálu a vypočtená vzdálenost nepřesná. Vzhledem k tomu, že převod je specifický pro daný hardware, nemá smysl zde uvádět další podrobnosti.

### 3. GENETICKÝ ALGORITMUS

Při užití genetického algoritmu [1] musíme navrhnout reprezentaci jednotlivých chromozómů (kódování řešení), velikost jejich populace, fitness funkci pro jejich ohodnocení a genetické operátory – mutaci a křížení. Též musíme zvolit, jakým způsobem budeme vybírat jedince ke křížení, mutaci a reprodukci. Důležitým prvkem návrhu je i způsob vytvoření první populace.

#### 3.1. CHROMOZÓM

Chromozómem musí být možno reprezentovat jakékoliv rozestavení libovolného počtu senzorů. Proto je vhodné každý senzor kódovat jako bod v rovině – dvojici souřadnic  $x$  a  $y$ . Celý chromozóm potom bude obsahovat tolik bodů, kolik je senzorů. Souřadnice jsou uloženy jako celá čísla.

#### 3.2. FITNESS FUNKCE

Fitness funkce je v tomto případě chybová funkce, která každému chromozómu přiřazuje reálné číslo, jenž určuje, jak moc se hodnocený chromozóm liší od optimálního řešení. Cílem tedy je tuto funkci minimalizovat. Fitness funkce je popsána rovnicí (1).

$$f(x) = \sum_{e \in E} \left( \frac{(h(e) - \text{length}(e))^2}{4} + \text{penalization}(e) \right) \quad (1)$$

$$\text{penalization}(e) = \begin{cases} (\min(e) - \text{length}(e))^4 & \text{if } \text{length}(e) < \min(e) \\ 0 & \text{else} \end{cases} \quad (2)$$

$E$	množina hran
$e$	aktuální hrana
$h(e)$	vzdálenost (ohodnocení hrany) vypočtená ze síly signálu
$\text{length}(e)$	vzdálenost senzorů hodnoceného chromozómu
$\text{penalization}(e)$	penalizace za hranu, která je kratší než nejkratší hrana z počátečního nebo koncového uzlu $e$ , vypočtená dle rovnice (2)
$\min(e)$	nejmenší ohodnocení hrany, která vede z počátečního nebo koncového uzlu $e$

#### 3.3. INICIALIZACE

Nultá populace se generuje náhodně. Souřadnice každého bodu musí být kladné kvůli použití jednobodového křížení jejich binární reprezentace, protože záporná čísla respektive jejich vyjádření v dvojkovém kódu způsobuje problémy. Velikost populace se osvědčila jako dvacetinásobek počtu senzorů.

#### 3.4. SELEKCE

Vybrání dvou rodičů, z kterých vznikne potomek, se provádí turnajem. Vyberou se náhodně dva chromozómy z populace a vezme se lepší z nich. Stejný postup se opakuje pro druhého rodiče.

#### 3.5. KŘÍŽENÍ

V chromozómu se vzájemně kříží sobě si odpovídající body. S pravděpodobností:

- 90 % se provede jednobodové křížení binární reprezentace pro každou souřadnici zvlášť
- 10 % se provede aritmetické křížení dle rovnice (3).

První typ křížení slouží k základnímu rozestavení bodů, druhý je pak jemnější posun k doladění pozice a zmenšení chyby. Pravděpodobnost křížení chromozómu je 95 %.

$$\begin{aligned}x &=rx_a+(1-r)x_b \\y &=ry_a+(1-r)y_b\end{aligned}\tag{3}$$

$x, y$	souřadnice bodu potomka
$x_a, y_a$	souřadnice bodu z prvního rodiče
$x_b, y_b$	souřadnice bodu z druhého rodiče
$r$	náhodně zvolená konstanta v intervalu $\langle 0; 1 \rangle$

### 3.6. MUTACE

Operátor mutace posune bod o náhodně zvolenou vzdálenost v každé ose. Pravděpodobnost posunu každého bodu v chromozómu  $p=2/N$ , kde  $N$  je počet bodů. Pravděpodobnost mutace chromozómu je 10 %.

### 3.7. NORMALIZACE

Normalizace je speciální operace vytvořená jen pro tuto aplikaci genetického algoritmu. Provádí se před přidáním chromozómu do populace. Projdou se všechny body chromozómu a naleznou se nejmenší hodnota pro osu  $x$  a  $y$ . Tato hodnota se poté od všech bodů odečte. Tím dostaneme všechna řešení do jednoho místa a poté lépe fungují genetické operátory, zejména křížení.

### 3.8. NAHRAZENÍ STARÉ POPULACE

Nová populace nahradí populaci starou po dosažení stejného počtu chromozómů, jako měla předcházející populace. Jedno procento nejlepších ze staré populace, minimálně však 1 chromozóm, přejde do nové populace beze změny. Tím zaručíme, že nikdy nepřijdeme o nejlepší řešení.

## 4. ZÁVĚR

Genetický algoritmus popsáný v tomto textu je jedním z výstupů mé bakalářské práce, v rámci které jsem ho implementoval a vyzkoušel na testovacích i reálných datech. Přesnost algoritmu je závislá především na přesnosti naměřených dat ze senzorů a případně na převodu síly signálu na vzdálenost. Dle experimentů je úspěšnost nalezení přibližné topologie 68 %. V případě úspěšného nalezení přibližné topologie algoritmus již velkou nepřesnost nepřináší, jelikož jde hlavně o poměry vzdáleností a vzájemnou polohu senzorů.

## PODĚKOVÁNÍ

Tato práce probíhala za podpory výzkumného záměru Výzkum informačních technologií z hlediska bezpečnosti, MSM0021630528 a fakulního projektu Pokročilé bezpečné, spolehlivé a adaptivní IT, FIT-S-11-1.

## REFERENCE

- [1] Sivanandam, S. N., Deepa, S. N.: Introduction to Genetic Algorithms, Springer, 2008, ISBN 978-3-540-73189-4