

**Igor LEŠŠO¹, František KREPELKA², Patrik FLEGNER³,
Milan ŠUJANSKÝ⁴**

**VÝSKUM MOŽNOSTI APLIKÁCIE METÓDY VEKTOROVÉHO KVANTOVANIA
PRI EFEKTÍVNOM RIADENÍ PROCESU ROZPOJOVANIA HORNÍN ROTAČNÝM
VŔTANÍM**

**RESEARCH OF APPLICATION POSSIBILITY OF VECTOR QUANTISATION
METHOD FOR EFFECTIVE PROCESS CONTROL OF ROCKS DESINTEGRATION
BY ROTARY DRILLING**

Abstract

The subject of the paper is investigation of the properties of concurrent vibroacoustic signal in the process of rock massif separation with the method of rotary drilling. The aim is to investigate the possibilities of using this signal as an integrating information source for the purposes of identification of the process of separation from the viewpoint of efficiency of the set mode (pressure, revolutions, indenter) under current geotechnical conditions. Investigated is the possibility of the process status recognition by method of vector quantisation.

Key words: rock desintegration, vibro-acoustic signal, method of vector quantisation

Úvod

Rotačné vrtanie patrí medzi kľúčové spôsoby rozpojovania horniny, a to nie len pri banskej činnosti, ale aj v širších oblastiach geotechnológií [1, 2, 3]. Najefektívnejšie rozpojovanie horniny je v tzv. objemovej oblasti, ktorú je možné dosiahnuť správnou voľbou pracovného nástroja a pracovného režimu, s prihliadnutím na geomechanické vlastnosti rozpojovanej horniny. Teoretický výskum rozpojovania hornín rotačným vrtaním a následné experimenty na vŕtnom stande Ústavu geotechniky Slovenskej akadémie vied ukázali, že existuje optimálny - efektívny režim vrtania z hľadiska mernej spotreby energie w (J/m³), z hľadiska opotrebovania rozpojovacieho nástroja, ale aj z hľadiska rýchlosti vrtania v (m/s) [4, 5]. Tieto tri kritéria optimálneho režimu sú splnené približne v jednom (efektívnom) pracovnom režime (optimálne otáčky - n_{opt} , optimálny prítlak - F_{opt}). Tieto skutočnosti viedli k myšlienke efektívneho riadenia procesu vrtania. Ďalší výskum ukázal, že v blízkosti efektívneho režimu procesu vrtania má sprievodný vibro-akustický signál špecifické identifikovateľné vlastnosti [6, 7].

V príspevku sú uvedené prvé čiastkové výsledky v oblasti návrhu systému riadenia procesu vrtania hornín, založeného na rozpoznávaní geomechanickej triedy horniny metódou vektorového kvantovania. Pritom potrebné informácie o charaktere procesu sú získavané zo signálu sprievodných vibro-akustických emisií.

¹ prof., Ing., CSc., TU v Košiciach, FBERG, Katedra informatizácie a riadenia procesov, ul. B. Němcovej 3, 040 01 Košice, Slovenská republika, igor.lesso@tuke.sk

² host. doc., Ing., CSc., ÚGT SAV, ul. Watsonova 45, 043 45 Košice, Slovenská republika, krepelka@saske.sk


³ Ing., PhD., TU v Košiciach, FBERG, Katedra informatizácie a riadenia procesov, ul. B. Němcovej 3, 040 01 Košice, Slovenská republika, patrik.flegner@tuke.sk

⁴ Ing., Procesná automatizácia, A. s. Košice, milan.sujansky@zoznam.sk

Definovanie problému

Problém riadenia procesu rozpojovania horniny má svoje špecifiká. Hlavným problémom je skutočnosť, že tento proces je vnútorne komplikovaný a jeho stavové veličiny sú štandardnými metódami v reálnych podmienkach nemerateľné [18, 19]. Kľúčovou otázkou je dostatok informácií o vplyve režimu vrtania na samotný priebeh rozpojovania konkrétnej horniny. Pod pojmom „režim rozpojovania“ rozumieme synergický efekt hlavných technologických zložiek procesu vrtania, ktorými sú tieto akčné veličiny: prítlak vrtného nástroja na čelo vrtu F (N), otáčky vrtného nástroja n (ot.s⁻¹), prietok výplachu za časovú jednotku Q (m³s⁻¹) a kvalita výplachu, ktorá je daná jeho fyzikálno-chemickými parametrami. Všetky tieto zložky sú na sebe nezávislé, je možné ich v priebehu vrtania samostatne ovládať. Znalosť režimov vrtania je základom poznania procesu rozpojovania hornín rotačným vrtaním.

Zo systémového hľadiska je proces vrtania horniny možné zjednodušene chápať ako systém, charakterizovaný súborom veličín, z nich niektoré vieme ovplyvňovať, ale niektoré nie (obr. 1). Parametre w a φ sú stavové veličiny procesu, ktoré nie sú v reálnych podmienkach priamo merateľné. Na proces rozpojovania vplyvajú aj ďalšie stavové veličiny: vlastnosti indentora (vrtného nástroja) a geomechanické vlastnosti práve rozpojovaného horninového masívu.



Obr. 1 Proces rozpojovania horniny ako objekt riadenia, riadený systém
 n -otáčky vrtného nástroja (ot.min⁻¹), F - prítláčna sila (prítlak) F (N),
 Q - množstvo výplachu vrtu vodou (m³s⁻¹), v - rýchlosť odvrtu (mm.s⁻¹),
 M_k - krútiaci moment (N.m), w -špecifická práca rozpojovania (J.m⁻³),
 $\varphi = v/w$ -pracovná schopnosť nástroja (m.s⁻¹. J⁻¹. m³).

Úloha syntézy riadenia takto definovaného procesu vrtania horninnového masívu pri požiadavke udržiavania efektívneho režimu s podmienkou maximalizácie účelovej funkcie $\varphi = v/w$ naráža na problém, že je nereálne vytvoriť adekvátny analytický matematický model procesu. Proces vrtania je totiž z hľadiska fundamentálneho modelovania príliš komplikovaný a empiricky získané modely majú platnosť len v konkrétnych podmienkach. Sledovaný proces rozpojovania je však silne stochastický a nestacionárny vplyvom meniacich sa geomechanických podmienok, ale aj vplyvom

rôzneho stupňa opotrebovania indentora. K tomuto problému sa pridružujú aj problémy s merateľnosťou hodnoty účelovej funkcie v reálnych podmienkach.

Východiskom je vyhnúť sa klasickému systému riadenia využívajúceho model procesu a riešiť systém riadenia založený na niektorej z moderných metód riadenia zložitých procesov, kde zdrojom zložitosti môžu byť nelinearity, nestacionarita, ťažko popísateľné stochastičnosti, nemerateľnosť parametrov, mnohokriteriálnosť, a pod. Medzi takéto moderné metódy riadenia patria aj metódy založené na tzv. umelej inteligencii.

Vo výskume otázky efektívneho riadenia procesu rozpojovania horninového masívu rotačným vŕtaním sa vychádzalo z intuitívnej predstavy, že sprievodný vibroakustický signál obsahuje informácie o charaktere procesu rozpojovania z hľadiska geomechanických vlastností horniny a z hľadiska efektívnosti samotného procesu vŕtania. Táto predstava sa experimentálne potvrdila [6, 7]. V ďalšom sa uvažovalo s dvomi variantmi riešenia.

a) parametrické riadenie s klasifikáciou rozpojovaných hornín

Tento variant predpokladá, že rozpojované horniny sú rozdelené do tried na základe podobných geomechanických vlastností a im odpovedajúceho optimálnemu spôsobu vŕtania. Pre každú triedu hornín sú experimentálnym alebo expertným spôsobom určené parametre efektívneho režimu vŕtania (druh indentora, F , n , Q). Systém v procese vŕtania v reálnych podmienkach priebežne identifikuje triedu práve rozpojovanej horniny na základe špeciálnej analýzy sprievodného vibro-akustického signálu [8, 9, 10, 11]. Na základe takto rozpoznanej triedy horniny nastavuje jej priradený efektívny režim vŕtania. Samotná klasifikácia hornín je založená na využití neurónovej siete ako klasifikátora a na metóde vektorového kvantovania [12].

b) spätnoväzobné riadenie s nepriamym meraním kritéria efektívnosti procesu

Pri tomto variante riadenia procesu vŕtania sa vychádza z výsledkov doterajšieho výskumu, ktoré potvrdili, že efektívny režim vŕtania horniny sa prejavuje špecifickými príznakmi v sprievodnom vibro-akustickom signáli [6, 7, 8]. V procese vŕtania je priebežne vyhodnocovaný sprievodný vibro-akustický signál a súčasne je režim procesu (n , F) stabilizovaný tak, aby príznaky v signáli odpovedali efektívnemu režimu procesu s maximálnou hodnotou účelovej funkcie $\varphi = v/w$.

Tento príspevok sa v ďalšom zaoberá prvým variantom riadenia procesu rozpojovania hornín rotačným vŕtaním. Ide o parametrické riadenie, kde kľúčovú úlohu zohráva klasifikácia hornín a metóda vektorového kvantovania príznakového priestoru sprievodného vibro-akustického signálu.

Popis metódy

Metóda vektorového kvantovania patrí do kategórie metód umelej inteligencie, pracujúcich s neurónovými sieťami [15, 16]. V značnej miere sa využíva v oblasti číslícového spracovania signálu, napr. pri analýze hovorového signálu pre účely jeho rozpoznávania, prenosu a syntézy. V týchto aplikáciach plní úlohu klasifikátora. Táto metóda sa v literatúre označuje aj ako samoorganizujúce Kohonenové mapy [13]. Vo výskume metód parametrického riadenia procesu rozpojovania horninového masívu sa skúmajú možnosti využitia L –úrovňového n -dimenzionálneho vektorového kvantizátora pre účely klasifikácie rozpojovaných hornín, čo umožňuje následne v zmysle parametrického riadenia nastaviť odpovedajúci efektívny režim vŕtania.

Zásadným a rozhodujúcim krokom pri aplikácii vektorového kvantizátora ako klasifikátora je vhodné definovanie tzv. príznakov ako náhodných premenných so spojitou amplitúdou, ktorých hodnoty ako reálne čísla umožňujú dostatočne diferencovane rozlišovať jednotlivé triedy objektov, resp. stavov. Skupina n príznakov tvorí potom n –zložkový vektor príznakov $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ v spojitom (v mplitúde) n -rozmernom vektorovom priestore $V^n(R)$. Ďalej v tomto vektorovom priestore $V^n(R)$ sa definuje konečná množina tzv. kódových (reprodukčných) vektorov $A_L = \{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_L\}$, kde tieto vektory $\mathbf{a}_l = [a_{l1}, a_{l2}, \dots, a_{ln}]^T$, $l=1,2,\dots,L$ odpovedajú jednotlivým rozlišovacím úrovniám objektov, resp. stavov, ktorým obecné hovoríme triedy. Množina reprodukčných vektorov A_L sa nazýva kódovou knihou. Tieto vektory potom v procese klasifikácie predstavujú vzory (príznačkov) jednotlivých tried.

L –úrovňový n –dimenzionálny kvantizátor je teda definovaný kódovou knihou A_L a delením spojitého vektorového priestoru $V^n(R)$ na L spojitých podpriestorov

$V_l^n(R)$, pričom väčšinou platí, že $\bigcup_{l=1}^L V_l^n(R) = V^n(R)$. Tento kvantizátor realizuje zobrazenie

$$q: V^n(R) \rightarrow A_L, \quad (1)$$

resp.

$$q: \left\{ \mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \right\}_{i=1}^{\infty} \rightarrow \left\{ \mathbf{a}_l = [a_{l1}, a_{l2}, \dots, a_{ln}]^T \right\}_{l=1}^L, \quad (2)$$

čo vyjadruje aj zápis

$$\mathbf{a}_l = q(\mathbf{x}) \text{ pre } \mathbf{x} \in V_l^n(R). \quad (3)$$

Úlohou L –úrovňového n –dimenzionálneho vektorového kvantizátora je teda každému vstupnému vektoru príznakov $\mathbf{x}_j \in V^n(R)$, $j = 1, 2, \dots, \infty$ priradiť reprodukčný vektor (vzor) $\mathbf{a}_l \in A_L$, $l = 1, 2, \dots, L$. Reprodukčné vektory \mathbf{a}_l sú väčšinou opäť n –zložkové, pričom tieto zložky majú ale diskkrétne amplitúdy. Týmto spôsobom teda vektorový kvantizátor prevádza súčasne klasifikáciu (zatriedňovanie) vstupných príznakových vektorov na základe daných vzorov pre jednotlivé rozlíšiteľné triedy.

Samostatným problémom pri metóde vektorového kvantizátora je definovanie špeciálnej funkcie $\rho(\mathbf{x}_1, \mathbf{x}_2)$, ktorá by vhodne vyjadrovala „vzdialenosť“ $|\mathbf{x}_1 - \mathbf{x}_2|$ medzi dvoma vektormi v priestore $V^n(R)$. Jej úlohou je citlivo vyjadriť mieru odlišnosti dvoch príznakových vektorov. Ide o zobrazenie $\rho: V^n(R) \times V^n(R) \rightarrow R$. Táto funkcia je súčasťou kvantizátora a slúži na výber „najbližšieho“ kódového

vektora $\mathbf{a}_l \in A_L$ k vstupnému príznakovému vektoru $\mathbf{x} \in V^n(R)$. Tiež je ju možné použiť pri optimálnom návrhu kódovej knihy [8, 11] a pri výpočte veľkosti tzv. kvantizačného šumu (miery skreslenia) [6, 11]. Pri návrhu funkcie $\rho(\mathbf{x}_1, \mathbf{x}_2)$ sa musí vychádzať z možností tzv. lineárnej vektorovej algebry.

Lineárna vektorová algebra definuje nad n –dimenzionálnym lineárnym vektorovým priestorom tieto aritmetické operácie [14]: rovnosť vektorov, súčet vektorov a súčin medzi vektorom a skalárom. Pre určité špeciálne výpočty v tomto vektorovom priestore je ďalej definovaná operácia skalárneho súčinu dvoch vektorov takto:

$$(\mathbf{x}_1, \mathbf{x}_2) = \sum_{j=1}^n x_{1j} x_{2j}. \text{ Vzhľadom na to, že príznakový priestor } V^n(R) \text{ je definovaný}$$

nad telesom reálnych čísel, ide o euklidovský priestor, pre ktorý je možné s využitím uvedenej aritmetiky vyjadriť tzv. LP normu:

$$L_P = \left(\sum_{i=1}^n |x_i|^P \right)^{1/P} = (\mathbf{x}, \mathbf{x}, \dots, \mathbf{x})^{1/P}. \quad (4)$$

Pre $P=2$ ^{krát} dostávame vzťah pre dĺžku (absolútna hodnota, norma) vektora:

$$|\mathbf{x}| = \left(\sum_{i=1}^n x_i^2 \right)^{1/2} = (\mathbf{x}, \mathbf{x})^{1/2}$$

Podobne je možné definovať vzdialenosť medzi dvoma vektormi v euklidovskom priestore:

$$|\mathbf{x}_1 - \mathbf{x}_2| = \left(\sum_{i=1}^n (x_{1i} - x_{2i})^2 \right)^{1/2}. \quad (5)$$

V praxi pri metóde vektorového kvantovania sa funkcia $\rho(\mathbf{x}_1, \mathbf{x}_2)$ definuje často na základe vzťahov (5) alebo (4). V týchto prípadoch funkcia $\rho(\mathbf{x}_1, \mathbf{x}_2)$ spĺňa v nekonečnej neprázdnej množine vektorov $V^n(R)$ všetky tri vlastnosti tzv. metriky:

1. $\rho(\mathbf{x}_i, \mathbf{x}_j) \geq 0$, pričom $\rho(\mathbf{x}_i, \mathbf{x}_j) = 0 \Leftrightarrow \mathbf{x}_i = \mathbf{x}_j$; pozitívna definitnosť,
2. $\rho(\mathbf{x}_i, \mathbf{x}_j) = \rho(\mathbf{x}_j, \mathbf{x}_i)$; symetria,
3. $\rho(\mathbf{x}_i, \mathbf{x}_k) \leq \rho(\mathbf{x}_i, \mathbf{x}_j) + \rho(\mathbf{x}_j, \mathbf{x}_k)$; trojuholníková nerovnosť.

V tomto prípade vektorové kvantovanie pracuje v tzv. metrickom priestore, ktorý je definovaný nekonečnou množinou n –zložkových lineárnych aritmetických vektorov a metrikou: $(V^n(R), \rho)$. Funkciou $\rho(\mathbf{x}_1, \mathbf{x}_2)$ ako metrika tu skutočne vyjadruje vzdialenosť medzi vektormi. Príkladom metriky, ktorá spĺňa všetky tri vyššie uvedené vlastnosti, je napr. priamo tzv. euklidovská metrika (5).

V iných zložitejších prípadoch funkcia $\rho(\mathbf{x}_1, \mathbf{x}_2)$ nespĺňa podmienky metriky a namiesto vzdialenosti vektorov sa uvádza pojem „miera skreslenia“ [11].

V prípade využitia vektorového kvantizátora ako klasifikátora stavov (objektov) je potom jeho úlohou priradiť každému vstupnému vektoru príznakov $\mathbf{x}_j \in V_n(R)$, $j = 1, 2, \dots, \infty$ najbližší reprodukčný vektor (vzor) $\mathbf{a}_l \in A_L$, $l = 1, 2, \dots, L$, čo vyjadruje podmienka

$$\min \left\{ \rho(\mathbf{x}_j, \mathbf{a}_l) \right\}_{l=1}^L. \quad (6)$$

Kľúčom k úspešnosti klasifikácie touto metódou vektorového kvantovania je návrh kvalitnej kódovej knihy A_L . Táto kniha vzorov by mala zabezpečiť minimálnu chybu kvantovania $\Delta_l = |\mathbf{x} - \mathbf{a}_l|$, resp. minimálnu strednú kvadratickú chybu aproximácie vektorov \mathbf{x} vzormi \mathbf{a}_l : $\min \varepsilon = \min \sum_{i=1}^L \int_{C_i} \Delta_i^2 p(\mathbf{x}) d\mathbf{x}$, kde C_i predstavuje oblasť (okolie) prislúchajúcu vzoru \mathbf{a}_i , pričom platí, že $\mathbf{x} \in C_i$. Zrejme teda platí $C_i = V_i^n(R)$, $i = 1, 2, \dots, L$.

Na vytvorenie takto koncipovanej kódovej knihy A_L sú dve možnosti. Ide o proces učenia neurónovej siete, a to učenie s učiteľom a o učenie bez učiteľa.

Prvou možnosťou (tzv. učenie s učiteľom) je empirické stanovenie vzorov \mathbf{a}_i , $i = 1, 2, \dots, L$ offline spôsobom s využitím tzv. trénovacích vstupných dát, čo sú príznakové vektory patriace do i -tej triedy. Podstatou tohto algoritmu je iteračný výpočet vzorového príznakového vektora \mathbf{a}_{C_i} na základe postupnosti D príznakových vektorov danej triedy $\{\mathbf{x}_k \in C_i\}_{k=0}^{D-1}$. Tento algoritmus vyjadruje výpočtová schéma:

$$\begin{aligned} \mathbf{a}_{C_i}(0) &= \mathbf{x}_0 \\ \mathbf{a}_{C_i}(k+1) &= \mathbf{a}_{C_i}(k) + \mu_k [\mathbf{x}_{k+1} - \mathbf{a}_{C_i}(k)] = \\ &= \mathbf{a}_{C_i}(k) + \mu_k \Delta_{C_i}(k+1), \text{ pre } k = 0, 1, \dots, D-1, \end{aligned} \quad (7)$$

kde $\mathbf{a}_{C_i}(k)$ je kódový vektor (vzor), reprezentujúci i -tú triedu v k -tom iteračnom kroku, D je počet príznakových vektorov v trénovacej množine pre triedu C_i , $\Delta_{C_i}(k+1) = \rho(\mathbf{x}_{k+1} - \mathbf{a}_{C_i}(k))$ je vzdialenosť medzi novým príznakovým vektorom a poslednou polohou vzoru triedy, resp. tzv. miera skreslenia. Miera posunutia μ_k má na počiatku procesu učenia hodnotu 1, potom sa priebežne znižuje smerom k hodnote 0 podľa vzťahu

$$\mu(k) = \mu(k-1) - \Delta\mu, \quad (8)$$

kedy sa už vzor ďalej nespresňuje.

Druhou možnosťou je vytváranie kódovej knihy priebežne v procese tzv. samoučenia systému (zhluková metóda), kedy sa priebežne v procese reálnej klasifikácie a súčasného spracovávania vstupných príznakových vektorov $\mathbf{x}_k, k = 1, 2, \dots$ spresňujú už definované vzory \mathbf{a}_i tried $C_i, i = 1, 2, \dots, L$ tak, aby bola minimalizovaná priemerná kvantovacia chyba aproximácie všetkých vstupných vektorov, ktoré doposiaľ boli zatriedené do príslušnej triedy C_i :

$$\mathbf{a}_c : \min \frac{1}{n_{C_i}} \sum_{j=1}^{n_{C_i}} |\mathbf{x}_j - \mathbf{a}_{c_i}|. \quad (9)$$

V prípade, že klasifikátor rozpozná novú triedu (neexistuje dostatočne blízky vzor), zaradi ho do množiny vzorov A^L . Aj pri tomto spôsobe vytvárania kódovej knihy sa uplatňuje iteračná výpočtová schéma (7).


Dosiahnuté výsledky

Na experimentálnom vŕtnom stande Ústavu geotechniky SAV bola prevedená séria meraní smerujúcich k aplikácii popísanej metódy vektorového kvantovania pre účely parametrického riadenia procesu rozpojovania horniny rotačným vŕtaním. Vŕtané boli horniny andezit, vápenec, žula, kremeň a tehla ako umelá hornina.


Ako možné zložky príznakového vektora boli skúmané:

- ☐ časový priebeh a rozptyl vibro-akustického signálu,
- ☐ Fourierove koeficienty výkonového spektra sprievodných akustických emisií na frekvenčnom rozsahu 0 až 22 kHz,
- ☐ koeficienty Wienerovho filtra ako parametrického modelu procesu vŕtania [17].


Na obrázkoch 2 až 4 sú znázornené rozptyly σ^2 postupnosti 200 realizácií sprievodného akustického signálu ($f_{vz} = 44$ kHz, dĺžka každej realizácie 1500 vzoriek), a to pri rôznych prítlakoch. Na základe vzniknutých zhlukov bodov je vidieť, že maximálny rozptyl signálu sa dosahuje pri určitom prítlaku, v závislosti na hornine, charakterizovanej jej geomechanickými vlastnosťami. Podľa [7] je to súčasne prítlak odpovedajúci efektívnemu režimu vŕtania. Na základe týchto poznatkov je možné uvažovať s parametrom σ^2 ako s jedným z príznakov pre klasifikáciu hornín. Na obr. 5 je znázornený priebeh parametra σ^2 po dobu 200 s vŕtania do andezitu pri rôznych prítlakoch. Priebehy sú v súlade s obrázkom 2.




Obr. 2 Andezit - $\sigma^2 = f(F)$




Obr. 3 Vápenec - $\sigma^2 = f(F)$



Obr. 4 Žula - $\sigma^2 = f(F)$



Obr.5 Andezit - $\sigma^2 = f(F, t)$



Obr. 6 L_2 norma signálov ako vektorov


Na obr. 6 je znázornená hodnota dĺžky (L_2 norma) príznakového vektora x , počítaná podľa vzťahu (4). Zložkami vektora boli vzorky akustického signálu s počtom 1024. Andezit a vápenec majú hodnoty tejto miery vzájomne veľmi blízke, avšak dostatočne diferencovateľné od žuly. Tento poznatok zodpovedá zisteniam ohľadom prítlaku, vyvolávajúceho maximálny rozptyl signálu (obr. 2 až 4), čo indikuje efektívny režim vrtania (viď vyššie). Aj tu sa vápenec a andezit chovajú podobne ale rozdielne od žuly. Táto skutočnosť dáva predpoklady využitia normy časového priebehu vibrodiagnostického signálu ako vhodného príznaku pri klasifikácii hornín.

V rámci výskumu bol overovaný samotný algoritmus procesu učenia neurónovej siete, resp. procesu vytvárania kódovej knihy AL ako súboru vzorov jednotlivých tried hornín $\{C_i\}_{i=1}^L$. Jadrom tohto algoritmu je iteračná výpočtová schéma (7), ktorá zabezpečuje mechanizmus posúvania vzoru vždy smerom k novému tréningovému príznakovému vektoru, ale s postupne klesajúcou mierou posunutia μ . Cieľom učenia je, aby výsledná poloha vzoru triedy bola čo najbližšie k centroidu, resp. k ťažisku množiny príznakových vektorov tréningových dát. Z tohto hľadiska úspešnosť tohto algoritmu silne závisí na správnej voľbe počiatočnej hodnoty miery posunutia $\mu(0)$ a na voľbe parametra tlmenia $\Delta\mu$ vo vzťahu (8).


Na obr. 7 sú znázornené prvé štyri kroky učenia klasifikátora na tréningovej množine príznakových vektorov triedy C_i v dvojrozmernom príznakovom priestore. Spracovaním príznakových vektorov x_0 až x_4 pomocou výpočtovej schémy (7, 8) sa vzor triedy dostáva postupne do pozície a_{C_i} (4). Pritom boli definované tieto hodnoty parametrov: $\mu(0) = 1$, $\Delta\mu = 0.1$. Je vidieť, že pri týchto hodnotách parametrov sa vzor približuje postupne k ťažisku x_T tréningových dát. Pri nevhodne volených hodnotách parametrov však táto metóda učenia môže divergovať (obr. 8). Ťažisko tréningovej množiny príznakových vektorov bolo počítané vzťahom

$$x_i^T = \frac{\sum_{j=1}^D p(x_{ij}) \cdot x_{ij}}{\sum_{j=1}^D p(x_{ij})}, \quad i = 1, 2, \dots, n \quad (10)$$


kde x_{ij} predstavuje hodnotu i –tého príznaku v j –tom príznakovom vektore tréningovej množiny dát, $p(x_{ij})$ je odhad pravdepodobnosti tejto hodnoty podľa Gaussovho rozdelenia.




Obr. 7 Prvé štyri kroky procesu učenia (postupné vytváranie vzoru triedy definovanej v dvojrozmernom príznakovom priestore); pozn: body v dolnej časti priestoru odpovedajú inej triede



Obr. 8 Predčasné „utlmenie“ procesu učenia už po 11. kroku vplyvom nevhodne volených počiatočných parametrov $\mu(0)$ a $\Delta\mu$ (+ -príznaky, * - vzor)



Obr. 9 Fitovaná závislosť vzdialenosti naučeného vzoru triedy od ťažiska tréningových dát pri rôznej voľbe parametra $\Delta\mu$ v intervale 0.001 až 0.1



Obr. 10 Vytvorenie vzorov dvoch tried hornín v trojrozmernom príznakovom priestore.

Na obr. 9 je znázornená fitovaná závislosť vzdialenosti medzi výsledným vzorom triedy hornín a ťažiskom trénovacej množiny vektorov na voľbe parametra tlmenia $\Delta\mu$ miery posunutia $\mu(k)$. Trénovacia množina dát pozostávala z 200 šesťzložkových príznakových vektorov. Je vidieť, že existuje optimálne tlmenie, pri ktorom sa dosiahne maximálne priblíženie vзору k ťažisku trénovacej množiny, čím sa splní podmienka (9). Tento poznatok je dôležitý pre využitie výpočtovej schémy (7) v procese samoučenia (učenie bez učiteľa), kedy sa hľadá vzor pre novú, resp. doteraz nepoznanú triedu hornín.

Obrázok 10 ilustruje úspešný proces učenia, kedy sa vytvorili vzory dvoch tried charakterizovaných trojrozmerným príznakovým priestorom.

Záver

V príspevku sú zverejnené prvé čiastkové výsledky aplikácie metódy vektorového kvantovania pri efektívnom riadení procesu rozpojovania hornín rotačným vrtaním. Ide o parametrické riadenie procesu s využitím neurónovej siete ako klasifikátora rozpojovaných hornín do tried z hľadiska ich geomechanických vlastností. Skúmaná bola možnosť využitia sprievodného vibroakustického signálu na výpočet príznakov, ktoré vo dostatočne diferencovali horniny podľa ich geomechanických vlastností. Pozitívne výsledky sa ukázali vo využití niektorých metód spracovania signálu v časovej oblasti. Pre ďalší výskum v tomto smere majú značný význam poznatky o vhodnej stratégii procesu vytvárania kódovej knihy vzorov tried hornín.

Literatúra

- [1] Strnište, K. (1988): Hlbinné vrtanie, skriptum VŠT v Košiciach, Košice 1988
- [2] Strnište, K. (1992): Hlbinné vrtanie, Alfa Bratislava, Bratislava 1992, ISBN 80-05-0131-1
- [3] Trnka, O., Balla, L. a Herel, J. (1969): Hlubinné dobývání rudných a nerudných ložísk, SNTL ALFA, Praha 1969
- [4] Krupa, V. a Pinka, J. (1998): Rozpojovanie hornín
- [5] TU v Košiciach, Vydavateľstvo Štrotek, Košice 1998, BN 80-88896-10-X
- [6] Sekula, F. (1992): Súbor prác z oblasti výsledkov výskumu rozpojovania hornín habilitačná práca, FBERG TU v Košiciach, Košice 1992
- [7] Leššo, I. (2004): Teória signálov pre priemyselnú informatiku
- [8] ES/AMS, Košice, 2004, ISBN: 80-8073-186-1
- [9] Leššo, I., Krepelka, F., Flegner, P. and Pandula, B. (2007): Research of methods for quality evaluation of rocks desintegration by rotary drilling, ISSN 1213-1962, vol. VII, 2/2007, p. 165 - 174
- [10] Leššo, I., Flegner, P., Pandula, B. and Horovčák, P. (2007): New principles of process control in geotechnics by acoustic methods.
- [11] In: Metallurgy. vol. 46, no. 3 (2007), p. 165-168. ISSN 0543-5846.
- [12] Sekula, F., Grexová, S. (2001): Monitorovanie rozpojovania pri plnoprofilovom razení líniových podzemných diel, Acta Montanistica Slovaca, 6 (2001)
- [13] Kaláb, Z., Častová, N. and Lyubushin, A. A. : Contribution to application of the Automatic classification of seismological signals

- [14] Documenta Geonica, ÚG AVČR, , s. 48 – 58.
- [15] Psutka, J., et al. (2006): Mluvíme s počítačem česky
- [16] ACADEMIA, Praha 2006, ISBN 80-200-1309-1
- [17] Gersho, A. and Gray, R. M. (1992): Vector quantisation and signal compression, Springer, 1992, ISBN 978-7923-9181-4
- [18] Deboeck, G. and Kohonen, T. (1998): Visual explorations in finance with self – organizing maps, Springer, 1998, ISBN 3-540-76266-3
- [19] Birkhoff, G. a MacLane, S. (1979): Prehľad modernej algebry, Alfa, Bratislava, 1979
- [20] Sinčák, P. a Andrejková, G. (1996): Neurónové siete, Elfa s.r.o., Košice, 1996
- [21] Hertz, J., Krogh, A. and Palmer, R. (1991): Introduction to the Theory of Neural Computation, Addison Wesley publishing, 1991
- [22] Flegner, P., Leššo, I. and Pandula, B. (2007): Wiener predicting filter as parameter model process of rock separation by rotary drilling ,Transactions of the VSB – Technical university of Ostrava, Civil engineering series,
- [23] ISSN 1213-1962, vol. VII, 2/2007, p. 51 – 59
- [24] Panda, A. (2000): Hodnotenie spôsobilosti meradiel.
- [25] TD 2000-DIAGON 2000, VUT Brno, Zlín, 2000, s.239-242, ISBN 80-214-1578-9.
- [26] Panda, A. and Pandová, I. (2000): Statistical Process Control. Principles of Statistics., Transactions of the Universities of Košice 2/2000, TU, Košice2000, s.20-23, ISSN 1335-2334.