

KLASIFIKÁTOR MODULACÍ S VYUŽITÍM UMĚLÉ NEURONOVÉ SÍTĚ

Marie Richterová¹, David Juráček²

¹ Univerzita obrany, Katedra KIS, ² PČR MŘ Brno

Abstrakt

Článek se zabývá rozpoznáváním analogových a diskrétních modulovaných signálů v programovém prostředí MATLAB. Klasifikátor modulací na bázi umělé neuronové sítě je schopen rozpoznávat amplitudově modulované signály (AM, DSB, SSB), kmitočtově modulované signály (FM) a z diskrétních modulovaných signálů klasifikuje ASK, FSK a PSK.

1 Úvod

Automatické rozpoznávání modulací je rychle se rozvíjející oblast analýzy signálů. Z hlediska tohoto aspektu je věnována velká pozornost výzkumu a vývoji algoritmů pro rozpoznávání modulovaných signálů. Potřeby praxe si postupně vynutily řešit otázku automatické klasifikace vzorků přijatých signálů s využitím počítačů a dostupného software.

2 Klíčové příznaky pro rozpoznávání modulovaných signálů

Modulované signály nesoucí skutečnou informaci mají charakter náhodných veličin, jejich průběh a priori určit nemůžeme a při jejich zkoumání lze popsat jen jejich pravděpodobnostními charakteristikami. Reálné signály lze popsat veličinami okamžitá amplituda, okamžitá fáze a okamžitý kmitočet, které u skutečných signálů mají také náhodný charakter. Reálný signál lze také popsat pomocí statistických momentů různých řádů [1, 2, 5].

Obvykle se k vyhodnocování modulací využívají takové statistické charakteristiky, které mají nejen matematický význam, ale i fyzikální význam. Lze využít např. směrodatnou odchylku náhodné veličiny, která zde bude mít význam efektivní hodnoty změny. Kromě toho je vhodné využít také exces, který vyjadřuje vlastnosti hustoty rozložení pravděpodobnosti náhodné veličiny ve vztahu ke Gaussovu rozložení. Vhodně vybrané pravděpodobnostní charakteristiky pak lze využít přímo pro rozlišení jednotlivých modulací.

Pro rozpoznání reálných modulovaných signálů pomocí počítače je tedy třeba vykonat tyto operace [2, 6, 7]:

- převedení reálného signálu $s(t)$ na diskrétní formu $x(t_i)$ pomocí vzorkování s vhodným vzorkovacím kmitočtem),
- transformaci reálného signálu $x(t_i)$ na analytický signál $z(t_i)$,
- výpočet okamžité amplitudy zkoumaného signálu $a(t_i) = |z(t_i)|$,
- výpočet okamžité fáze signálu $\Phi(t_i) = \arg\{z(t_i)\}$,
- výpočet okamžitého kmitočtu signálu $f(t_i)$,
- výpočet vhodných klíčových příznaků,
- vlastní klasifikace.

Pro vlastní klasifikaci je nutné určit prahové hodnoty pro jednotlivé příznaky a porovnat s nimi hodnoty dosažené u jednotlivých příznaků.

Pro rozpoznávání analogových a diskretních modulací je možno využít tyto klíčové příznaky [2, 6, 7]:

- maximální hodnotu výkonové spektrální hustoty centrované normované okamžité amplitudy signálu γ_{\max} ,
- směrodatnou odchylku absolutní hodnoty centrované nelineární složky fáze pro časový segment, kde je signál nad šumem σ_{AP} ,
- směrodatnou odchylku přímé hodnoty nelineární složky fáze na intervalu, kde signál vystupuje ze šumu σ_{DP} ,
- symetrii spektra signálu vůči kmitočtu nosné P .

Pro odlišení analogových a digitálních modulací lze využít další příznaky:

- směrodatnou odchylku absolutní hodnoty normované centrované okamžité amplitudy σ_{AA} ,
- směrodatnou odchylku normované centrované okamžité amplitudy pro signál vystupující ze šumu σ_A ,
- směrodatnou odchylku absolutní hodnoty normovaného okamžitého kmitočtu pro signál vystupující ze šumu σ_{AF} ,
- exces normované centrované amplitudy μ_{42A} ,
- exces normovaného kmitočtu μ_{42F} .

S využitím těchto příznaků lze provést základní rozpoznání modulovaných signálů.

3 Postup při rozpoznávání modulovaných signálů pomocí umělých neuronových sítí

Proces rozpoznávání reálných modulovaných signálů pomocí počítače musí obsahovat tyto základní procedury:

1. Načtení pole vzorků zkoumaného signálu.
Toto pole bude obsahovat určitý počet po sobě následujících vzorků N_{vz} .
2. Výběr N vzorků a vytvoření vektoru reálného signálu \bar{X} .
Počet prvků vektoru $N < N_{vz}$ a platí $N = 2^m$, kde m je celé číslo.
3. Transformace vektoru reálného signálu na vektor analytického signálu \bar{Z} .
4. Výpočet vektoru okamžité amplitudy \bar{a} , vektoru okamžité fáze $\bar{\Phi}$ a vektoru okamžitého kmitočtu \bar{f} .
5. Výpočet klíčových příznaků pro rozpoznání druhu modulace.
6. Návrh struktury umělé neuronové sítě.
7. Vytvoření trénovací množiny.
8. Proces učení umělé neuronové sítě s pomocí učitele.
9. Vlastní procedura rozpoznání.

Uvedené procedury je možno podle potřeby doplnit dalšími procedurami, které mohou určení druhu modulace usnadnit nebo zpřesnit.

4 Výběr struktury umělé neuronové sítě pro rozpoznávání analogových a diskrétních modulací

Po prostudování charakteristických vlastností analogových a diskrétních modulovaných signálů, vlastností a struktury umělých neuronových sítí, se jako nejvhodnější pro řešení problému rozpoznávání analogových a diskrétních modulovaných signálů jeví vícevrstvé umělé neuronové sítě [2, 4, 6, 7]. Aplikací struktury vícevrstvé neuronové sítě se budeme zabývat podrobněji v následujícím textu.

Postup návrhu struktury neuronové sítě je založen na testování různých struktur za účelem dosažení přijatelné přesnosti [2, 6, 7].

Rozpoznání analogových a diskrétních signálů, které je založené na aplikaci umělé neuronové sítě se skládá ze tří hlavních etap:

- 1) Předzpracování a extrakce klíčových příznaků ze zkoumaných vzorků signálů.
- 2) Sestavení struktury sítě a proces učení s učitelem s cílem najít optimální váhy a ovlivnit minimalizaci chyby v síti.
- 3) Etapa testování činnosti sítě a vlastní proces klasifikace reálného vzorku signálu.

Pro rozpoznání analogových a diskrétních modulovaných signálů jsou vhodné dva typy umělých neuronových sítí, založené na počtu skrytých vrstev [2, 6, 7]:

- neuronová síť s jednou skrytou vrstvou,
- neuronová síť se dvěma skrytými vrstvami.

Všechny tyto užívané sítě jsou přizpůsobivé z hlediska snížení sumy kvadratické chyby.


Z hlediska řešení problému rozpoznávání analogově a diskrétně modulovaných signálů je velmi obtížné vybrat optimální strukturu umělé neuronové sítě. V [2] je popsáno využití umělé neuronové sítě s jednou nebo se dvěma skrytými vrstvami neuronů pro rozpoznávání diskrétních modulací.

V případě použití umělé neuronové sítě s jednou skrytou vrstvou neuronů se velmi obtížně nastavují prahy a váhy. S tím může být spojena i chybná klasifikace signálu. Tedy tato struktura umělé neuronové sítě je pro rozpoznávání analogových a diskrétních modulací nevhodná.

Jedním z možných řešení jsou umělé neuronové sítě s více vrstvami skrytých neuronů, jak je uvedeno v [2, 6, 7]. Struktura této sítě je na obr. 1. Uvedená síť je složena z jedné vstupní, jedné výstupní a z dvou vrstev se skrytými neurony.

Na vstup neuronové sítě jsou přivedeny hodnoty sedmi charakteristických příznaků signálu a na výstupu neuronové sítě se objeví matice cílů, udávající předpokládaný analogový nebo diskrétní modulovaný signál (AM, DSB, LSB, USB, FM, ASK, FSK, PSK).

Pro praktickou realizaci umělé neuronové sítě byla zvolena struktura uvedená v [2, 6], kde počet neuronů vstupní vrstvy je roven počtu příznaků (7 neuronů), výstupní vrstva (11 neuronů) je tvořena počtem neuronů rovnajícím se počtu cílů ve výstupní matici, která odpovídá množině rozpoznávaných modulovaných signálů a obě skryté vrstvy, jsou tvořeny každá z patnácti neuronů (viz obr. 1).



Obr. 1: Struktura umělé neuronové sítě pro klasifikaci analogových a diskretních modulací

Pro praktický návrh struktury umělé neuronové sítě a pro proces jejího učení jsou využity standardní funkce z programového prostředí MATLAB a to:

- funkce *rand*s - inicializace prahů a vah,
- funkce *trainbpa* – trénink sítě pomocí algoritmu backpropagation.
- a ostatní funkce z toolboxu NNET pro návrh a trénink umělých neuronových sítí.

5 Tvorba tréninkové množiny

Aby bylo možné spustit proces rozpoznávání reálných vzorků modulovaných signálů, je nutné vytvořit trénovací množinu. Trénovací množina se skládá ze dvou submatic. První submatice je tvořena charakteristickými příznaky dané modulace, druhá submatice se skládá z cílů, jak je ukázáno na obr. 2.

	1	2	3	n	
P ř í z n á k y	y_{znam}					
	δ_{ap}					
	δ_{dp}					
	P					
C í l e	1	0	0	0	0	
	0	1	0	0	0	
	0	0	1	0	0	
	0	0	0	1	0	
	0	0	0	0	1	
	0	0	0	0	0	1
	AM	DSB	LSB	USB	FM	FSK

Obr. 2: Příklad struktury trénovací množiny

V submatici Příznaky jsou do sloupců ukládány hodnoty charakteristických příznaků, které odpovídají jednotlivým druhům modulací. V submatici Cíle jsou uloženy hodnoty vektorů korespondující s druhy modulací.

Z vektoru hodnot charakteristických příznaků a vektoru hodnot odpovídajícího cíle je vytvořen sloupcový vektor (viz obr. 2), který je uložen do souboru „*.mat“ ve vnitřním kódu MATLABu. V praxi to znamená, že přidáním nového vzoru do trénovací množiny se trénovací matice rozrůstá do šířky. Tedy, trénovací množina může mít obecně až n vzorů, minimální počet vzorů musí odpovídat počtu zkoumaných druhů modulovaných signálů (v tomto případě je to 11 typů modulovaných signálů, tedy je potřeba minimálně 11 vzorů).

6 Experimentální ověření činnosti klasifikátoru modulací

Pro experiment bylo k dispozici několik druhů vzorků reálných signálů ve formátu „*.wav“. Reálný signál, který obsahoval cca 800 000 vzorků rozdělíme náhodným procesem na 1000 segmentů o délce cca 20 000 vzorků, které podrobíme klasifikaci. Budeme určovat kolik procent vzorků z 1000 segmentů má správnou klasifikaci.

Praktické experimenty byly provedeny pro architekturu neuronové sítě uvedené na obr. 1 s patnácti neurony ve dvou skrytých vrstvách a hodnotu prahu 0.25, kdy signál vystupuje ze šumu. Tréninková množina obsahuje osmnáct vzorů.

Výsledky experimentů jsou uvedeny v následující tabulce.

Tabulka 1: Výsledky klasifikace vzorků reálných modulovaných signálů

Vzorek signálu	Správná klasifikace v %										
	ASK	FSK2	FSK4	PSK2	PSK4	Neznámý	AM	DSB	LSB	USB	FM
AM-RA3EV							82,4	17,6			
LSBFV								21,2	78,8		
LSB6V									88,6	11,4	
LSB2V						15			74,9	10,1	
FM-R12V											100
FM-R11V											100
FM-R10V								22,8			77,2
ASK	100										
PSK-2				77,2	22,8						
PSK-2-1				84,6	15,4						
PSK4				24,9	75,1						
FSK2		79,5	10,5			10					
FSK2-1		80,3	14,5			5,2					
FSK2-2		78,1	11			10,9					
FSK4		21,7	76,2			2,1					

7 Rozbor experimentálních výsledků

Provedené experimenty potvrdily, že navržená struktura umělé neuronové sítě je schopná rozpoznávat reálné vzorky analogově a diskretních modulovaných signálů s pravděpodobností větší jak 75 %. Je nutné zabezpečit správný proces tréninku a to tak, aby metrika daného prostoru měla přibližně stejnou vzdálenost od všech vzorů trénovací množiny (viz informace o trénovací množině uvedené v [2, 6, 7]). V praxi je to velmi obtížné a jde o velmi zdlouhavý proces, který představuje velké množství časově náročných experimentů.

Při procesu učení neuronové sítě bylo zjištěno, že s přibývajícimi vzory v trénovací množině se mění také dynamika jejího učení. V případě, že hodnoty tréninkových parametrů překročí své dané limity, neuronová síť pracuje neodpovídajícím způsobem.

V reálných aplikacích by bylo vhodné nalézt vyhovující algoritmus pro úpravu dynamiky učení umělé neuronové sítě, aby byly vhodné koeficienty nalezeny automaticky po přidání vzoru do trénovací množiny.

Na zvýšení pravděpodobnosti úspěšné klasifikace má také vliv proces předzpracování reálného vzorku signálu. Ovšem, proces předzpracování by měl být zvolen tak, aby nezanikly charakteristické vlastnosti (příznaky) ve zkoumaném vzorku signálu.

8 Závěr

Tento příspěvek byl věnován metodě klasifikace analogových a diskretních modulací klasifikátorem na bázi umělých neuronových sítí. Byly provedeny praktické experimenty s reálnými vzorky signálů. Popsaná metoda klasifikace signálů s využitím klasifikátoru na bázi umělých neuronových sítí je vhodná jak pro návrh samostatného automatického klasifikátoru, tak i pro sestavení doplňkového automatického klasifikátoru provozů. Z praktického hlediska by bylo vhodné realizovat automatizovaný klasifikátor provozů s víceúrovňovou neuronovou sítí, což by mohlo přispět ke zvýšení hranice míry správné klasifikace. Prezentované výsledky ukazují, že v případě klasifikace reálných vzorků signálů se míra správné klasifikace bude pohybovat nad 75 %.

Literatura

- [1] J. Anděl. *Matematická statistika*. SNTL, Praha, 1978.
- [2] E. E. Azzouz, A. K. Nandi. *Automatic Modulation Recognition of Communication Signals*. Kluwer Academic Publishers, London, 1996.
- [3] V. Žalud. *Moderní radioelektronika*. BEN, Praha 2000.
- [4] M. Šnorek, M. Jiřina. *Neuronové sítě a neuropočítače*. Vydavatelství ČVUT, Praha, 1996.
- [5] Z. Kotek, V. Mařík a kol. *Metody rozpoznávání a jejich aplikace*. Academia, Praha, 1993.
- [6] M. Richterová. *Signal Modulation Recognizer Based on Method of Artificial Neural Networks*. In Proceeding of Symposium PIERS, Hangzhou, China, 2005.
- [7] M. Richterová, A. Mazálek, K. Pelikán. *Modulation Classifier of Digitally Modulated Signals Based on Method of Artificial Neural Networks*. In Proceeding of the WSEAS Conferences: 4th WSEAS Int. Conf. on AEE'05. Prague, 2005.
- [8] H. Demuth, M. Beale. *Neural Network Toolbox. For Use with MATLAB*. User's Guid., ver. 4. The MathWorks, Inc., MA 01760-2098.

Kontakt

¹ Ing. Marie Richterová, Ph.D.

Univerzita obrany, Katedra KIS (K-209), Kounicova 65, Brno, 612 00,

e-mail: Marie.Richterova@unob.cz

² Ing. David Juráček

PČR MŘ Brno, Cejl 4/6, 602 00 Brno

E-mail: Davidjk@seznam.cz