

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE



TEZE K DISERTAČNÍ PRÁCI

České vysoké učení technické v Praze
Fakulta elektrotechnická
Katedra radioelektroniky

Ladislav Pospíšil

**MODELOVÁNÍ NELINEÁRNÍCH PRVKŮ
VYSOKOFREKVENČNÍCH OBVODŮ NEURONOVÝMI SÍTĚMI**

Doktorský studijní program: Elektrotechnika a informatika
Studijní obor: Radioelektronika

Teze disertace k získání akademického titulu "doktor", ve zkratce "Ph.D."

Praha, *říjen 2012*

Disertační práce byla vypracována v kombinované formě doktorského studia na Katedře radioelektroniky, Fakulty elektrotechnické ČVUT v Praze.

Uchazeč: Ing.Pospíšil Ladislav
Laboratoře LVR
Fakulta elektrotechnická, ČVUT v Praze
Technická 2, 166 27 Praha 6

Školitel: Doc.Ing.Josef Dobeš,CSc.
Katedra radioelektroniky
Fakulta elektrotechnická, ČVUT v Praze
Technická 2, 166 27 Praha 6

Školitel-specialista: ---

Oponenti:

.....

.....

Teze byly rozeslány dne:

Obhajoba disertace se koná dne v hod. před komisí pro obhajobu disertační práce ve studijním oboru Radioelektronika v zasedací místnosti č Fakulty elektrotechnické ČVUT v Praze.

S disertací je možno se seznámit na děkanátu Fakulty elektrotechnické ČVUT v Praze, na oddělení pro vědu, výzkum a zahraniční styky, Technická 2, Praha 6.

Prof.Ing.Miloš Mazánek,CSc.
předseda komise pro obhajobu disertační práce
ve studijním oboru
Radioelektronika
Fakulta elektrotechnická ČVUT, Technická 2, Praha 6

Obsah

1	SOUČASNÝ STAV PROBLEMATIKY	1
2	CÍL DISERTAČNÍ PRÁCE	2
3	METODY ZPRACOVÁNÍ	3
3.1	Zpřesnění analytického modelu tranzistoru MES-FET	3
3.2	Použitá neuronová síť	4
4	Přímý model	6
5	Korekční neuronová síť	7
6	Využití navzájem kooperujících neuronových sítí	8
7	VÝSLEDKY	8
7.1	Tranzistor pHEMT I - přímá metoda	8
7.2	Tranzistor pHEMT I - korekční metoda	9
7.3	Tranzistor pHEMT II - přímá metoda	11
7.4	Memristivní systém - kooperativní neuronové sítě	11
8	ZÁVĚR	13

1 SOUČASNÝ STAV PROBLEMATIKY

V současné době pro modelování mikrovlnných polovodičových prvků existuje mnoho modelů s různou složitostí modelu [25, 24, 9, 18] a také s různou přesností tohoto modelu [2, 23, 6, 22, 16], zde je také provedeno kvalitativní porovnání těchto modelů [3, 12, 14]. V [22] je provedeno porovnávání dynamické části a statické části modelu pro čtyři různé modely s naměřenými hodnotami a v [16] je provedeno porovnání statických parametrů devíti modelů použitých pro modelování tranzistoru GaAs MESFET¹. Tranzistor MESFET patří k základním aktivním prvků mikrovlnných obvodů, fyzikální princip činnosti tohoto tranzistoru je stejný jako u JFET tranzistoru, ale hradlo MESFET tranzistoru je od kanálu izolováno přechodem kov-polovodič [5]. Za přesnější model může být považován realistický² Parker a Skellernův model [18], nicméně identifikace parametrů tohoto modelu je často velice komplikovaná a tudíž prakticky nerealizovatelná [19]. Z tohoto důvodu jsou hledány jiné cesty jak zlepšit klasické modely přidáním funkce(í) pro zlepšení parametru(ů) těchto modelů [2, 23, 6, 16].

Modelování mikrovlnných obvodů za pomoci neuronové sítě obecně (nejen pro polovodičové prvky) jsou popsány v [27]. Různé typy modelů polovodičových prvků pomocí neuronové sítě jsou také popsány v [13, 1, 15, 17, 11, 8] – [13] představuje neuronové sítě pro empirické modelování v systémech technologického modelování TCAD, [1] představuje postup modelování tranzistorů HEMT, [15] představuje modelování tranzistorů řízených polem MOSFET a AC/DC charakteristiky bipolárních tranzistorů (BJT), [17] představuje modely na bázi AlGaAs a SiGe HBT pro „malé“ a „velké“ signály, [11] představuje lineární

¹Tranzistory MESFET se nejčastěji vyrábí na bázi GaAs – pohyblivost elektronů v GaAs je mnohem větší než v Si [5].

²Tento model je nazýván „realistický“ protože důsledně používá fyzikálních principů pro výstavbu systému rovnic [5].

nelineární modely tranzistorů pHEMT a Schottky diody a [8] představuje nový přístup v implementaci modelů tranzistoru MOS pomocí neuronové sítě do simulačního prostředí třídy SPICE. Hlavní důraz bude dále kladen na metody, které jsou popsány v [27] a dále popsány a simulovány na konkrétních příkladech.

2 CÍL DISERTAČNÍ PRÁCE

Tato práce se zabývá *Modelování nelineárních prvků vysokofrekvenčních obvodů neuronovými sítěmi* a z toho vyplývají následující dva hlavní cíle:

1. Ověřit zda s využitím *neuronové sítě* a různých metodik modelování, je možno vytvořit technicky použitelný model vysokofrekvenčních prvků dosahující větší přesnosti než dosavadní nejlepší analytický model. Z hlediska využitelnosti tohoto modelu k účelům simulace je z technického hlediska za dostatečné, je-li hodnota přesnosti $rms < 0,50\%$. Tato hodnota rms je pro účely identifikace charakteristik nelineární vysokofrekvenční prvků rozhodující a vypovídá o kvalitě takto vytvořeného modelu. Parametr rms^3 je zvolen pro porovnání s přesností analytických modelů, kde se používá.
2. Optimalizovat zvolené *neuronové sítě* z hlediska počtu *neuronů* v jednotlivých vrstvách a počtu vrstev této sítě identifikující zvolenou modelovanou strukturu, v našem případě vysokofrekvenční prvek. Při zachování odpovídající technicky použitelné přesnosti a průběhu identifikovaných charakteristik.

³Průměrná kvadratická relativní chyba.

3 METODY ZPRACOVÁNÍ

3.1 Zpřesnění analytického modelu tranzistoru MESFET

Budeme se věnovat jednak možnostem korekce analytického modelu tranzistoru MESFET, a jeho dalšího možného zpřesnění s využitím *umělých neuronových sítí* a různých metodik jejich využití. Náhradní obvod tohoto modelu je uveden na obrázku 1. Tento analytický model lze s výhodou využít pro modelování mikrovlnných tranzistorů na bázi GaAs označované jako GaAsFET a pseudomorfní HEMT (High Electron Mmobility Transistor), nebo např. také mikrovlnného varaktoru (lavinové fotodiody) s velice nelineárním průběhem kapacity v závislosti na napětí. Využívá se dynamická část modelu tranzistoru.

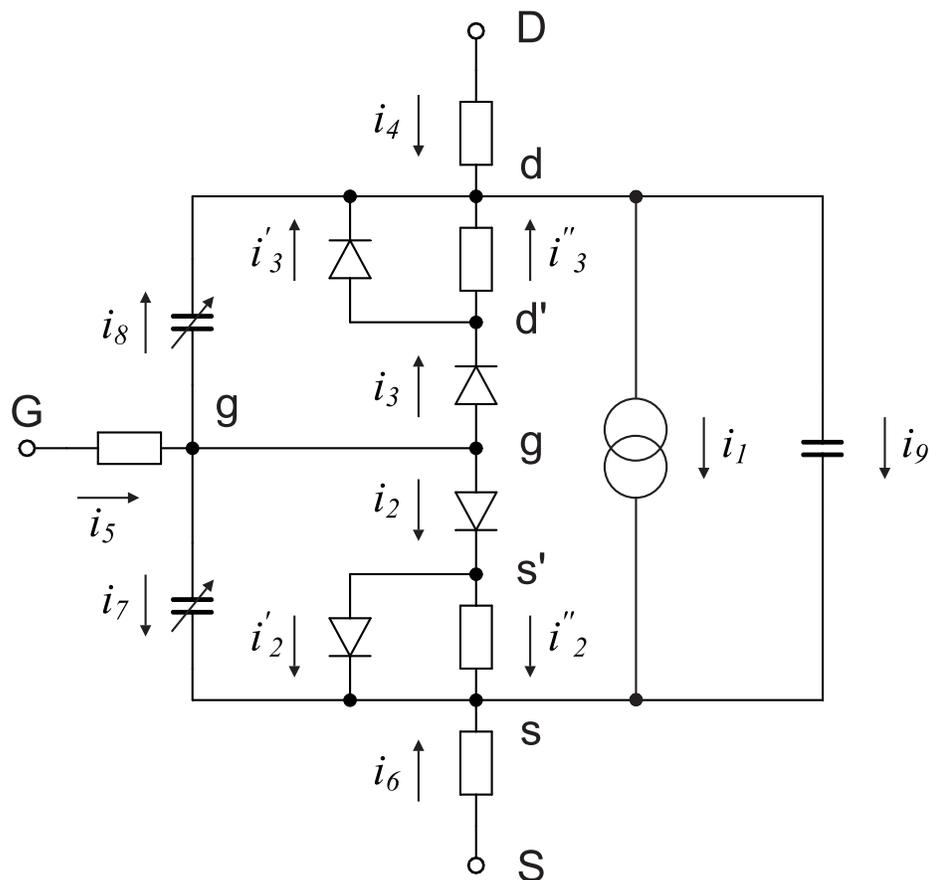
Přesnost modifikovaného modelu je jak pro statické tak i dynamickou část stále v řádu procent. Větší přesnosti lze dosáhnout za použití neuronové sítě, jednak jako přímý *neuro*⁴ model (užití pouze neuronové sítě), nebo jako zpřesňující korekční neuronovou síť, která je paralelně připojena k modifikovanému analytickému modelu. Tyto řešení můžeme považovat za efektivní a relativně jednoduchou cestu.

Statická část modelu je popsána jako u ostatních unipolárních tranzistorů nelineárním zdrojem proudu řízený napětím *gate-source* u_{gs} a *drain-source* u_{ds} , který je popsán rovnicemi (1):

$$i_1 = \begin{cases} 0 & \text{pro } (u_{gs} - U_T \leq 0), \\ \beta(u_{gs} - U_T)^{n_2}(1 + \lambda u_{ds}) \tanh(\alpha u_{ds}) & \text{pro } (u_{gs} - U_T > 0), \end{cases} \quad (1)$$

kde $u_{gs} = u_g - u_s$ a $u_{ds} = u_d - u_s$. Schottkyho dioda *gate-source* se

⁴Pod pojmem *neuro* modelem zde uvažujeme použití pouze neuronové sítě jako mode celého prvku.



Obrázek 1: Analytický model tranzistoru MESFET.

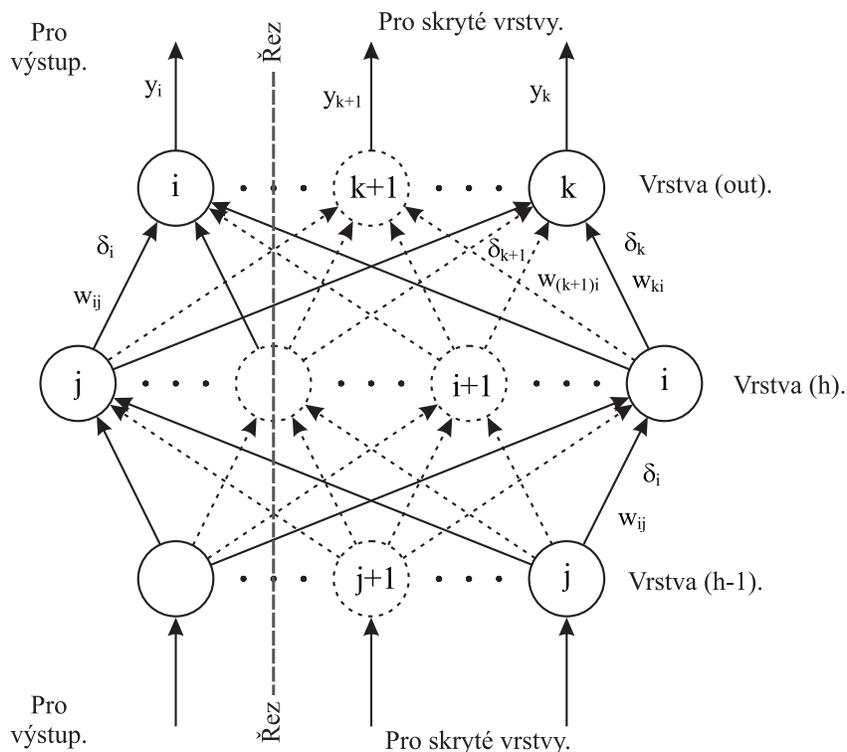
aproximuje dvojicí „diod“ definovaných Shockleyovými vztahy a paralelním rezistorem k druhé z nich.

3.2 Použitá neuronová síť

Definujme nejprve *neuronovou síť* takto:

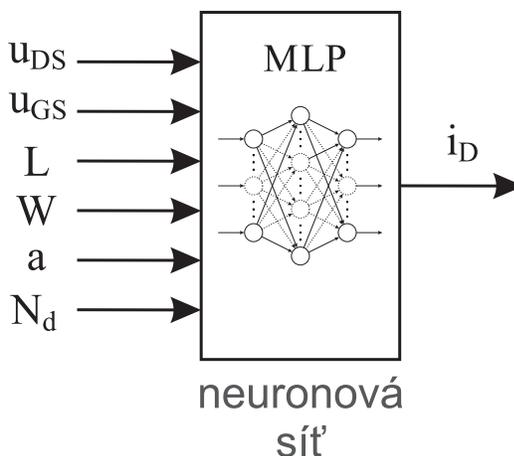
neuronová síť je orientovaný graf s ohodnocenými hranami kde rozeznáváme uzly vstupní, výstupní a skryté, a kde hrany reprezentují tok signálu. Hrany jsou ohodnoceny parametrem zpracování signálu, který je nazýván vahou.

V průběhu vývoje *neuronových sítí* se věnovala významná pozornost tzv. *vrstvomým neuronovým sítím*, disjunktní podmnožiny těchto *neuronových sítí* jsou tzv. *vrstvy*. Perceptronová síť (MLP - *multilayer perceptron*), je vrstvomá *neuronová síť* s dopřednými



Obrázek 2: Neuronová síť MLP -MultiLayer Perceptron.

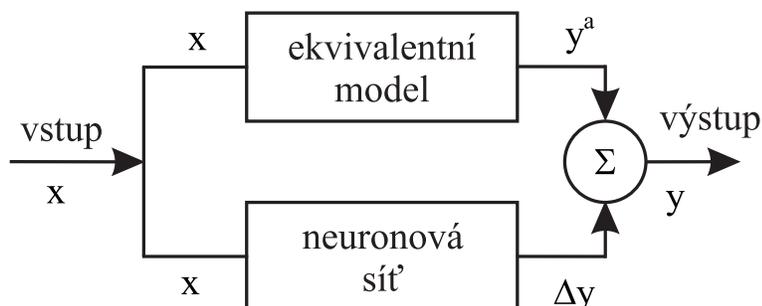
šířením a algoritmem učení *back propagation*. Vstupy každého *neuronu* jedné vrstvy jsou napojeny na výstupy všech *neuronů* vrstvy předchozí. Neexistují žádné vazby mezi vzdálenějšími vrstvami nebo mezi *neurony* v rámci jedné vrstvy. Každý neuron má tedy právě tolik vstupů, kolik je neuronů v nižší vrstvě. Vstupní vrstva sítě slouží pouze k distribuci vstupních hodnot. Pro přenosovou funkci vrstevových perceptronových sítí není vhodná funkce skoková ani lineární (u lineárních funkcí nemá smysl vytvářet více vrstev, protože jedna vrstva lineárních *neuronů* provádí lineární zobrazení a skládáním více lineárních zobrazení dostaneme zase jen lineární zobrazení). Budeme tedy používat nelineární *perceptrony*, který je pro řešení úlohy našeho typu výhodnější.



Obrázek 3: Modelování DC charakteristik tranzistoru MESFET.

4 Přímý model

Přímým přístupem modelujeme vnější chování prvku (modelovaného objektu) „přímo“ *neuronovou sítí*, jak uvádí [21]. Při použití této metody modelování není nutné zjišťovat vnitřní strukturu tranzistoru (obecně jakéhokoli „obecného“ modelovaného prvku), ani nutná znalost ekvivalentního obvodu s jeho parametry. Tranzistor je charakterizován svým vnějším chováním jako jsou stejnosměrné charakteristiky, nebo závislost s-parametrů. Vstupy takového modelu jsou parametry procesu např. pro tranzistory MESFET napětí *drain-source* u_{DS} (V_{DS}) a *gate-source* u_{GS} (V_{GS}) a fyzikální parametry tranzistoru např. délka kanálu L , šířka kanálu W atd. Jde-li o jediný konkrétní tranzistor, není nutno zahrnovat tyto fyzikální parametry do vstupu *neuro* modelu, parametry jsou konstanty a nepřinášejí žádnou informaci při procesu učení. Výstup z *neuro* modelu je proud protékající tranzistorem i_D (I_D).



Obrázek 4: Použití *neuronové sítě* pro zpřesnění analytického modelu.

5 Korekční neuronová síť

Jedna z dalších metod kombinovaného modelování je metoda zpřesnění analytického modelu⁵ korekční *neuronovou sítí* zapojenou paralelně s analytickým modelem (opět je nutná znalost analytického modelu), jak ukazuje obrázek 4. Princip je jednoduchý, k zpřesnění výsledného modelu se použije *neuronová síť*, která se naučí kompenzovat nepřesnosti analytického modelu. Vstupem *neuro* modelu jsou vstupní parametry analytického modelu například pro tranzistor pHEMT jde o napětí *drain-source* u_{DS} (V_{DS}) a napětí *gate-source* u_{GS} (V_{GS}). Jako dalším vstupem *neuro* modelu mohou být užity jiné vhodné parametry, například technologické parametry tranzistoru jako ukazuje obrázek 3, věnovaný přímému modelování. Naučená *neuronová síť* může provádět korekce pro více tranzistorů téže „rodiny“ [stejná technologie]. Výstupem je požadovaná korekce Δi_D (viz vzorec2), který koriguje analytický model v námi uvedeném příkladu pro tranzistor pHEMT.

⁵Může být užito i jiných modelů, které se mohou za použití *neuronové sítě* zpřesňovat.

6 Využití navzájem kooperujících neuronových sítí

V této metodě se využívá pro vytvoření celkového modelu propojení více *neuronových sítí* (pouze *neuronových sítí*), které vytvářejí celkový model. Jde o vzájemné propojení nezávislých kooperujících *neuronových sítí*.

Tato metoda je vhodná pro modelování prvků s komplikovanou charakteristikou jakou jsou například memristivní systémy vyznačující se hysterezí. Metoda byla navržena autorem tohoto textu a použita na konkrétním příkladu prvku s memristivní charakteristikou viz 8. Některé dosažené výsledky byly publikovány v [13] a [3], charakteristika byla získána z [4] (Nature) a [26].

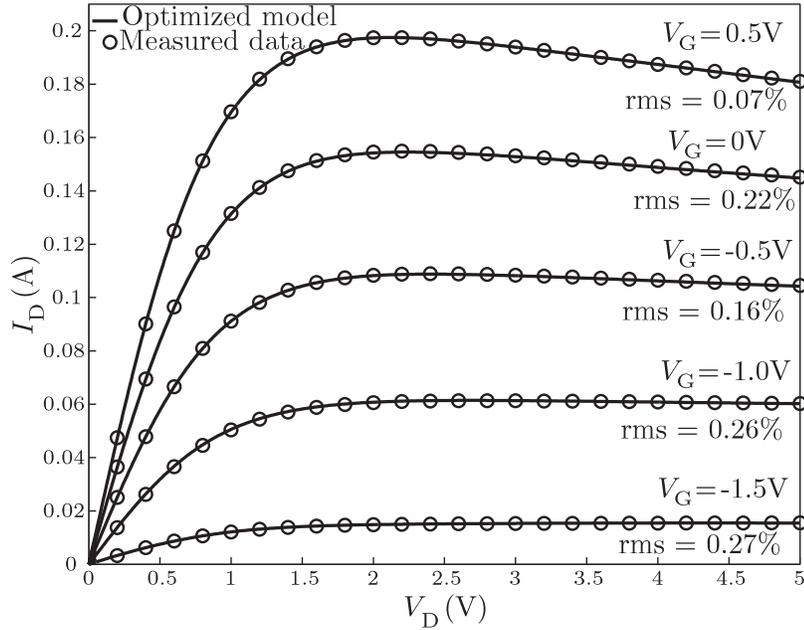
Není-li možno k modelování úlohy využít některou z výše popsaných metod, a je-li možno tuto úlohu rozdělit na více nezávislých podmnožin. Lze řešit tuto úlohu pro každou podmnožinu zvlášť, nezávisle na ostatních dílčích podmnožinách s využitím pouze *jedné neuronové sítě* a výše popsané „přímé“ metody v části 4 (obdoba superpozice). Pro ilustraci této metody je uveden příklad modelu *memristivního systému* v části 7.4, kdy tento komplikovaný prvek vzhledem k jeho charakteristikám viz obrázek 8, nelze modelovat pouze *jednou neuronovou sítí*, nebo některou zde popsanou kombinovanou metodou.

7 VÝSLEDKY

7.1 Tranzistor pHEMT I - přímá metoda

V tomto příkladu se pokusíme identifikovat volt-ampérové charakteristiky AlGaAs/InGaAs/GaAs pHEMT tranzistoru pomocí *neuronové sítě* se snahou o zlepšení průměrné relativní kva-

dratické odchyly rms . Na obrázku 5 je průběh volt-ampérové charakteristiky tohoto tranzistoru (kolečka \circ označují měřenou hodnotu, plná čára označuje hodnoty identifikované *neuronovou sítí*). Pro identifikaci tohoto průběhu byla použita „přímá“ metoda s neuronovou sítí MLP-2-5-4-5-1. Model obsahuje jeden vstup (napětí *gate-source* u_{GS}) a jeden výstup (proud *drainu* i_D), parametr u_{GS} (napětí *gate-source*) je konstanta a není zahrnut jako vstupní parametr modelu. Při tomto přístupu je nutné mít pro každý parametr u_{GS} zvlášť „naučenou“ *neuronovou sítí*. Průměrná kvadratická relativní odchyly $rms = 0.20\%$, tato hodnota rms ukazuje na velice dobrý výsledek identifikace.



Obrázek 5: Výsledek identifikace charakteristik tranzistoru pHEMT za použití neuronové sítě MLP-2-5-4-5-1 (pro všechny charakteristiky je společně $rms = 0.2\%$).

7.2 Tranzistor pHEMT I - korekční metoda

Výše popsáný přístup k modelování tranzistoru AlGaAs/InGaAs/GaAs pHEMT I *neuronovou sítí* patřili do kategorie „přímého“

modelování. Nyní se pokusíme představit jednu z možností kombinovaného přístupu (kombinace analytického modelu a *neuronové sítě*). Tento přístup využívá *neuronovou síť* k provedení korekce chyb analytického modelu. Na obrázku je uvedena závislost chyby analytického modelu na napětí u_{DS} pro jednotlivá napětí $u_{GS} \in \{-1,5V ; -1,0V ; -0,5V ; 0V ; 0,5V \}$. Odchylka analytického modelu a měřené hodnoty Δi_D je označena kroužkem (\odot). Tento rozdíl můžeme vyjádřit jako vzorec (2):

$$\Delta i_D = i_D^{(meas)} - i_D^{(identam)}, \quad (2)$$

kde $i_D^{(meas)}$ je změřený proud *drainem* tranzistoru a $i_D^{(identam)}$ je proud vypočtený analytickým modelem. O použitém analytickém modelu tranzistoru včetně jeho parametrů jsme se zmínili v úvodu této části. Pro identifikaci průběhu chyby $\Delta i_D(u_{DS}, u_{GS})$ (naznačujeme, že jde o funkci dvou proměnných u_{DS} a u_{GS}) byla použita *neuronová síť* MLP-2-8-10-6-1. Vstup *neuronové sítě* tvoří dvojice hodnot napětí u_{DS} a u_{GS} , výstup sítě je korekce proudu Δi_D použitého analytického modelu. Tento *neuro model* dosáhl průměrné kvadratické relativní chyby $rms = 7,56\%$ pro všechna měřená napětí u_{GS} . Hodnoty rms pro jednotlivé napětí u_{GS} jsou uvedena v obrázku. Jak je patrné z tohoto obrázku, největší chyba rms je pro napětí $u_{GS} = -1,5V$, kde hodnota rms dosahuje hodnoty $37,24\%$. Všechny ostatní chyby rms jsou pod $0,4\%$. Velikost chyby $rms = 37,24\%$ pro napětí $u_{GS} = -1,5V$ je způsobena faktem, že hodnoty odchylek proudu Δi_D jsou pro toto napětí blízké nule (rms analytického modelu pro napětí $u_{GS} = -1,5V$ je pouze $0,83\%$). Výsledná hodnota průměrné kvadratické relativní chyby korigovaného analytického modelu *neuronovou sítí* MLP-2-8-10-6-1 je $rms = 0,064\%$. Souhrn relativních chyb rms je uveden v tabulce 1.

Pro #1 jde o analytický model, pro #2 o přímý *neuro model* MLP-2-5-4-5-1 a pro #3 jde nepřímý korigovaný model (korekce

u_{GS} [V]	0,5	0	-0,5	-1,0	-1,5	celkem	
rms [%] ¹	3,10	2,34	2,06	1,93	0,83	2,05	#1
rms [%] ²	0,07	0,22	0,16	0,26	0,27	0,20	#2
$rms \times 10^{-3}$ [%] ³	1,86	0,70	2,06	6,96	310,00	64,00	#3

Tabulka 1: Porovnání metod modelování a jejich chyb rms .

je provedena za pomoci MLP-2-8-10-6-1).

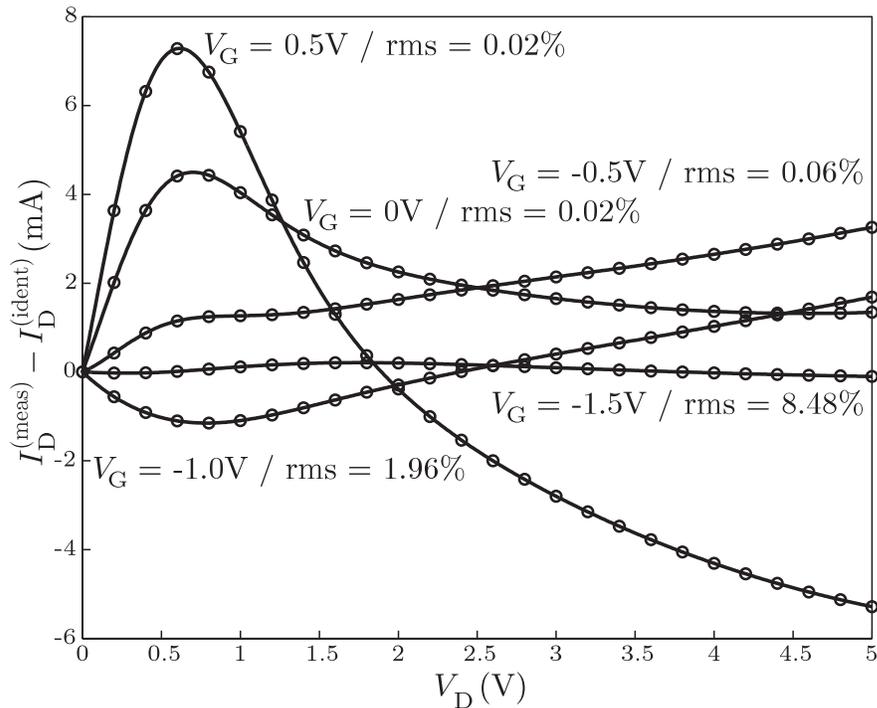
7.3 Tranzistor pHEMT II - přímá metoda

Na obrázku 7 je uvedena volt-ampérová charakteristika tranzistoru pHEMT II. Takto charakteristika byla identifikována z naměřených hodnot *neuronovou sítí* MPL-2-9-13-8-1 po proběhnutí 500 trénovacích epoch. Zde uvedený příklad vysokofrekvenčního tranzistoru pHEMT II pracující do frekvence 110GHz s využitím pouze jedné *neuronové sítě*. Charakteristiky k tomuto tranzistoru byly změřeny v italské Bologni (Dr. Svevo Monacovi, MEC, University of Bologna a University of Ferrara), což je jedno z mála pracovišť v Evropě schopno provést měření na takto vysokých frekvencích. K získání naměřených hodnot k tomuto tranzistoru přispěla práce[7].

7.4 Memristivní systém - kooperativní neuronové sítě

Charakteristika *memristivního systému* byla rozdělena na celkem 5 oblastí. Každá z těchto oblastí byla identifikovaná *neuronovou sítí*, jak je uvedeno na obrázku 8. Oblast 1 a 2 byli identifikovány jako funkční závislost $y = f(x)$, oblast 1 *neuronovou sítí* MLP-1-2-3-2-1 a oblast 2 *neuronovou sítí* MLP-1-3-4-2-1. Pro oblasti 3&4⁶ a 5 vzhledem k jejich průběhu, byla zvolena identifikace funkční závislosti $x = f(y)$. Oblast 3&4 (z praktických

⁶Původně rozdělené oblasti 3 a 4 byly identifikovány jako jeden celek.



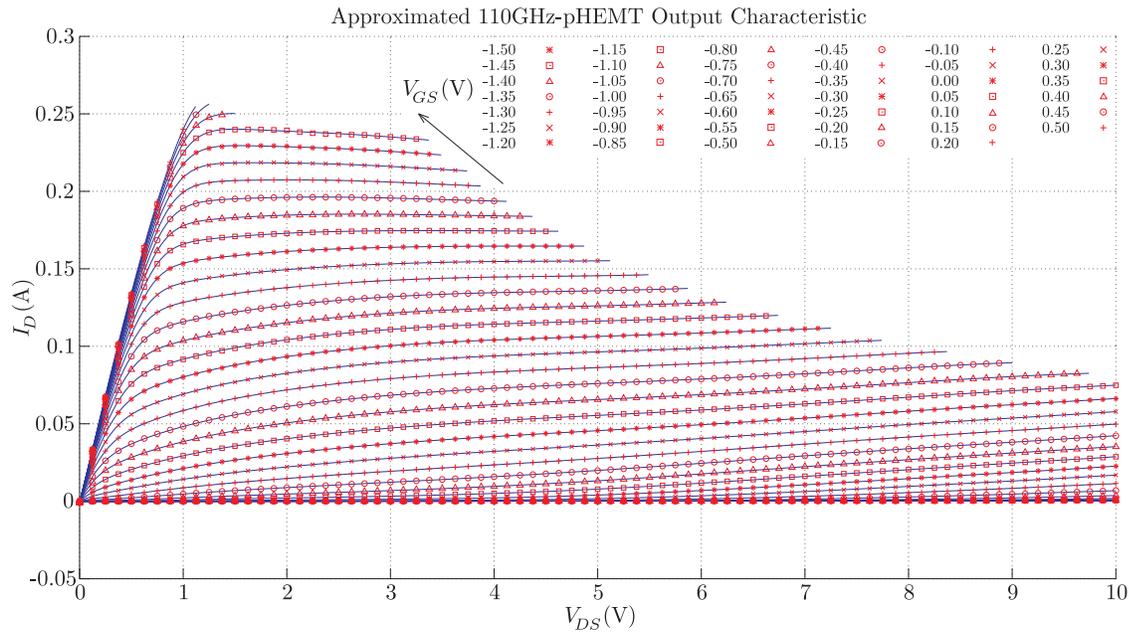
Obrázek 6: Výsledek aproximace rozdílů mezi naměřenými daty a (předešle identifikovaným) modifikovaným analytickým modelem, který je na obrázku 1), tento rozdíl je výstupem korekční neuronové sítě MLP 2-8-10-6-1 (pro naučení sítě bylo použito 1000 trénovacích epoch).

důvodů se nakonec oblasti 3 a 4 sdružili do jedné 3&4) *neuronovou sítí* MLP-1-5-7-3-1 a oblast 5 *neuronovou sítí* MLP-1-4-5-3-2-1.

Souhrn průměrných kvadratických relativních chyby *rms* a maximální relativní chyby δ_{max} pro jednotlivé oblasti včetně užitých *neuronových sítí* je uvedeno v tabulce 2.

Tato metoda byla navržena autorem tohoto textu, jak je uvedeno výše v 6. Některé dosažené výsledky byly publikovány v [13] a [3], charakteristika byla získána z [4] (Nature) a [26].

Jak je z této tabulky 2 patrné, je hodnota chyby *rms* pro jednotlivé modelované oblasti v řádu procent.



Obrázek 7: Výsledek identifikace charakteristik tranzistoru pHEMT II za použití neuronové sítě MLP-2-9-13-8-1.

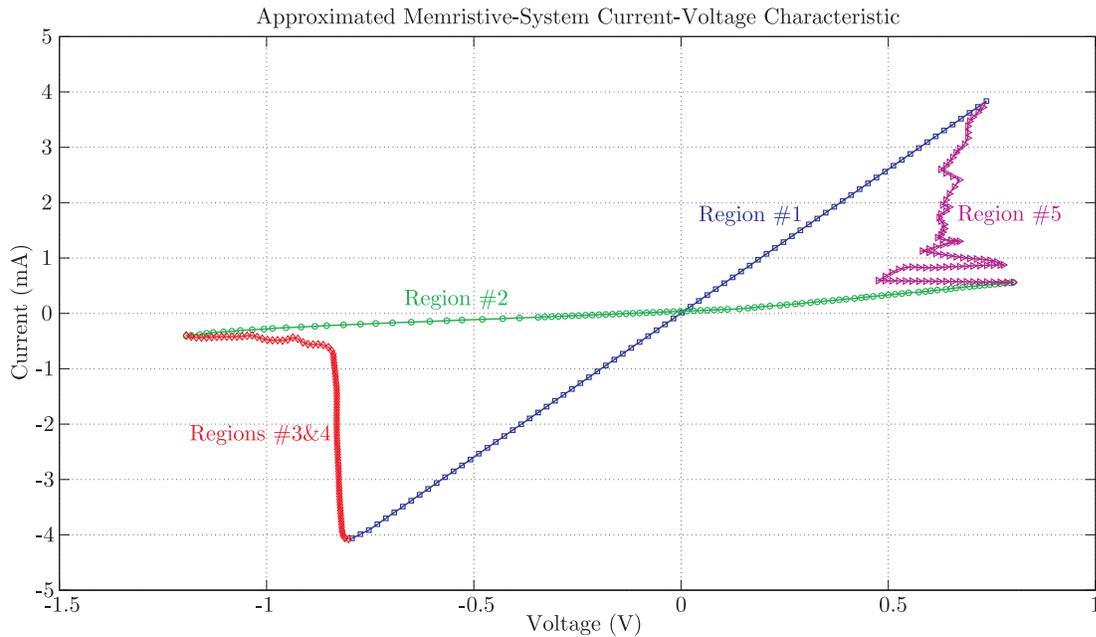
8 ZÁVĚR

Závěrem lze říci, že provedené experimenty potvrdily, že přesnost analytického modelu nemohou být lepší než cca v řádu procent. Zlepšení přesnosti těchto analytických modelů je možné a relativně jednoduché dosáhnout za pomoci neuronových sítí. Použitím „přímé“ neuronové sítě poskytuje procentuálně desetkrát větší přesnost, nicméně nejpřesnější výsledky má kombinace paralelní neuronové sítě s modifikovaným analytickým modelem. Byly provedeny různé experimenty s nejrůznějšími typy modelů a neuronových sítí (přímé modely, korekční a kombinované) na široké třídě vysokofrekvenčních prvků jako jsou například lavinová fotodiody, mikrovlnné tranzistory pHEMT I a pHEMT II (pracující až do frekvence 110GHz) a memristivní systém. Pro všechny typy sítí byla spolehlivě zvládnut proces jejich učení pomocí systému naměřených dat a sestaven postup jak

Oblast	Typ neuronové sítě	rms	δ_{max}
1	MLP-1-2-3-2-1	0,50%	$\approx 1,50\%$
2	MLP-1-3-4-2-1	0,86%	$\approx 2,00\%$
3&4	MLP-1-5-7-3-1	1,63%	$\approx 2,50\%$
5	MLP-1-4-5-3-2-1	7,65%	$\approx \times 10\%$

Tabulka 2: Souhrn užitých *neuronových sítí* pro identifikaci volt-ampérové charakteristiky *memristivního prouku* s použitím více *neuronových sítí* a jejich průměrných kvadratických relativních chyby rms a maximální relativní chyby δ_{max} .

naučenou síť použít při analýze elektronických obvodů. Parametry analytického modelu, tak i hodnoty synaptických vah neuronové sítě je možno získat za použití optimalizačních metod. Na řadě experimentů, které zde byly představeny se ukazuje, že optimální struktura nemusí být nutně komplikovanou strukturou. Obecně jsou doporučované dvě vnitřní skryté vrstvy neuronové sítě s typicky 4–8 neurony na vrstvu. Na základě realizací mnoha systematicky generovaných experimentů byl formulován závěr, podle kterého lze většinu mikrovlnných aktivních prvků spolehlivě identifikovat neuronovými sítěmi s dvěma skrytými vrstvami, každá z těchto vrstev obsahuje typicky 4-8 neuronů. Tento námi dosažený výsledek je v dobré shodě s doporučením definovaným v nejnovějších publikacích členy týmu vůdčí osobnosti v této oblasti, prof. Q.J.Zhanga. Byla ověřena experimentální přístup k možné optimalizaci neuronové sítě s využitím algoritmu Bayesovské regularizace, pro nalezení optimálního počtu skrytých vrstev neuronové sítě a počtu neuronů v těchto vrstvách. Tato proces byla ověřena na tranzistoru pHEMT I, pHEMT II a PJEFT a také na memristivním systému. Lze říci že takto navržená procedura vedla rychleji k výsledné optimální struktuře neuronové sítě než snaha o zautomatizování experimentálního přístupu hledání optimální (suboptimální) struktury neuronové sítě. Touto snahou se úlohu poněkud komplikuje, jak bylo uve-



Obrázek 8: Identifikovaná volt-ampérová charakteristika *memristivního prvku* s použitím 4 *neuronových sítí*.

deno výše. Dále je nutné posuzovat použité model z hlediska jeho „celkového“ chování například průběhů charakteristik atd. Dále byla zpracována metodika korektivních sítí pracujících jako opravný prostředek modifikovaného analytického modelu s přesností pod jedno procento. Tento výsledek je zcela dostačující z hlediska požadavků na přesnost modelu pro účely simulace. Byla také navržena principiálně nová metodika použití systému více vzájemně spolupracujících neuronových sítí pro identifikaci komplikovaných prvků s výraznou hystezí jakým je Pt – TiO_{2-x} – Pt memristivní systém. K těmto účelům další možné optimalizace neuronové sítě lze použít výše zmíněné Bayesovské regularizace, či některé z variant algoritmů konjungovaného gradientu, které sice pomaleji konvergují, ale hrozí menší riziko proskočení nějakého lokálního minima jako např. u rychleji konvergujícího Lavenberg-Marquardtova algoritmu. Pro účely optimalizace lze také využít některé metody „kleštění“ neuronové

sítě, jako je například metoda data mining, nebo optimalizaci s využitím evolučních algoritmů pro redukci parametrů sítě. Některé dílčí výsledky této práce byly publikovány za pisatelova spolutorství ve velmi dobře impaktovaném časopise nakladatelství Elsevier Solid-State Electronics (IF=1,494 ve Web of Science), dále je pisatel spoluautorem článku v impaktovaném časopise Radioengineering (IF=0,503) a prvním spoluautorem článku v časopise s dobrým faktorem SNIP (Scopus normalized impact per paper) 1,061. Dále byly výsledky publikovány na odborných konferencích oboru Circuits and Systems, především MWSCAS (IEEE International Midwest Symposium on Circuits and Systems. Některé obrázky a metody byly publikovány v knize Moderní radioelektronika. Časopis Radioengineering byl citován ve špičkovém časopise oboru Solid-State Electronics (kde bylo porovnání používaných modelů MESFET s řadou jiných modelů) a dále na konferenci IEEE International Conference on Solid-State and Integrated Circuit Technology indexované v IEEE Xplore a rovněž v zahraniční disertační práci.

Reference

- [1] CADDEMI, A., AND DONATO, N. Advanced simulation of semiconductor devices by artificial neural networks. *Journal of Computational Electronics 2* (2003), 301–307.
- [2] CAO, J., WANG, X., LIN, F., NAKAMURA, H., AND SINGH, R. An empirical pHEMT model and its verification in PCS CDMA system. In *29th European Microwave Conference* (Munich, Oct. 1999), pp. 205–208.
- [3] CURTICE, W. R. GaAs MESFET modeling and nonlinear CAD. *IEEE Trans. Microwave Theory Tech. 36* (Feb. 1988), 220–230.
- [4] D. B. STRUKOV, G. S. SNIDER, D. R. S., AND WILLIAMS, R. S. The missing memristor found. *Nature 453* (May 2008), 80–83.
- [5] DOBEŠ, J. *Návrh vysokofrekvenčních a mikrovlnných obvodů počítačem*. Vydavatelství ČVUT, 2006.
- [6] DOBEŠ, J. C.I.A.—A comprehensive CAD tool for analog, RF, and microwave IC's. In *8th IEEE Int. Symp. High Performance Electron Devices for Microwave and Optoelectronic Applications* (Glasgow, Nov. 2000), pp. 212–217.
- [7] GRÁBNER, M. *Identifikace parametrů nelineárního modelu HEMT ze systému rozptylových parametrů*. PhD thesis, České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra radioelektroniky, Únor 2008.
- [8] HAMMOUDA, H. B., MHIRI, M., GAFSI, Z., AND BESBES, K. Neural-based models of semiconductor devices for SPICE simulator. *American Journal of Applied Sciences 5*, 4 (2008), 385–391.
- [9] JASTRZEBSKI, A. K. Non-linear MESFET modeling. In *17th European Microwave Conference* (1987), pp. 599–604.
- [10] L. POSPÍŠIL, J. DOBEŠ, A. Y. Characterization of electronic circuit elements by exclusive and corrective artificial neural networks. *International Journal of Mathematics and Computers in Simulation 6*, 1 (Jan. 2012), 136–143.
- [11] LI, X., GAO, J., AND BOECK, G. Microwave nonlinear device modeling by using an artificial neural network. *Semicond. Sci. Technol. 21* (2006), 833–840.

- [12] MADJAR, A. A fully analytical AC large-signal model of the GaAs MESFET for nonlinear network analysis and design. *IEEE Trans. Microwave Theory Tech.* 36 (Jan. 1988), 61–67.
- [13] MATEI, R., DIMA, G., AND PROFIRESCU, M. D. TCAD modeling using a neural network based approach. In *Modeling and Simulation of Microsystems* (2001), pp. 518–521.
- [14] MCCAMANT, A. J., MCCORMACK, G. D., AND SMITH, D. H. An improved GaAs MESFET model for SPICE. *IEEE Trans. Microwave Theory Tech.* 38 (June 1990), 822–824.
- [15] MEIJER, P. B. L. *Neural Network Applications in Device and Subcircuit Modelling for Circuit Simulation*. Met lit. opg., Proefschrift Technische Universiteit Eindhoven, Philips Research Laboratories in Eindhoven, Netherlands, 2003.
- [16] MEMON, N. M., AHMED, M. M., AND REHMAN, F. A comprehensive four parameters I - V model for GaAs MESFET output characteristics. *Solid-State Electronics* 51, 3 (Mar. 2007), 511–516.
- [17] MUNSHI, K., VEMPADA, P., PRASAD, S., SÖNMEZ, E., AND SCHUMACHER, H. Small signal and large signal modeling of HBT's using neural networks. *Microwave Review* 9, 2 (Dec. 2003), 31–34.
- [18] PARKER, A. E., AND SKELLERN, D. J. A realistic large-signal MESFET model for SPICE. *IEEE Trans. Microwave Theory Tech.* 45 (Sept. 1997), 1563–1571.
- [19] PEJČINOVIĆ, B. Personal communication at ICECS. Sep. 2002.
- [20] POSPIŠIL, L., DOBEŠ, J., AND YADAV, A. Accurate Modeling of Unusual Electronic Circuit Elements with Artificial Neural Networks. In *Proceedings of 2nd Conference on Circuits, Systems, Control, Signals* (Athens, 2011), vol. 1, World Scientific and Engineering Academy and Society, pp. 150–155.
- [21] Q.J.ZHANG, AND K.C.GUPTA. *Neural Networks for RF and microwave design*. Artech Hous, 2000.
- [22] SIJERČIĆ, E., AND PEJČINOVIĆ, B. Comparison of non-linear MESFET models. In *9th IEEE Int. Conf. on Electronics, Circuits and Systems* (Dubrovnik, Sep. 2002), vol. III, pp. 1187–1190.

- [23] SMITH, D. H. An improved model for GaAs MESFETs. Tech. rep., TriQuint Semiconductors Corporation, 2000.
- [24] STATZ, H., NEWMAN, P., SMITH, I. W., PUCEL, R. A., AND HAUS, H. A. GaAs FET device and circuit simulation in SPICE. *IEEE Trans. Electron Devices* 34 (Feb. 1987), 160–169.
- [25] SUSSMAN-FORT, S. E., HANTGAN, J. C., AND HUANG, F. L. A SPICE model for enhancement- and depletion-mode GaAs FET's. *IEEE Trans. Microwave Theory Tech.* 34 (Nov. 1986), 1115–1119.
- [26] Z. BIOLEK, D. B., AND BIOLKOVÁ, V. Spice model of memristor with nonlinear dopant drift. *Radioengineering* 18, 2 (June 2009), 210–214.
- [27] ZHANG, Q. J., AND GUPTA, K. C. *Neural networks for RF and microwave design*. Artech House, Boston, 2000.

Přehled publikací Ladislav Pospíšila, Ing.

Reference

Seznam publikací vztahující se k disertaci

Publikace v impaktovaných časopisech

- [1] DOBEŠ, J., MÍCHAL, J., PAŇKO, V., AND POSPÍŠIL, L. Reliable procedure for electrical characterization of MOS-based devices. *Solid-State Electronics* 54, 10 (Oct. 2010), 1173–1184. (Web of Science IF = 1,493) **25%**
- [2] DOBEŠ, J., POSPÍŠIL, L. Enhancing the accuracy of microwave element models by artificial neural networks. *Radioengineering* 13, 3 (2004), 7–12. (Web of Science IF = 0,503) **50%**

Publikace v recenzovaných časopisech

- [3] POSPÍŠIL, L., DOBEŠ, J., YADAV, A. Characterization of electronic circuit elements by exclusive and corrective artificial neural networks. *International Journal of Mathematics and Computers in Simulation* 6, 1 (Jan. 2012), 136–143. (Scopus normaized impact per paper IF = 1,061) **33%**

Publikace excerptované WOS

- [4] DOBEŠ, J., MÍCHAL, J., PAŇKO, V., AND POSPÍŠIL, L. Reliable procedure for electrical characterization of MOS-based devices. *Solid-State Electronics* 54, 10 (Oct. 2010), 1173–1184. (Web of Science IF = 1,493) **25%**
- [5] DOBEŠ, J., POSPÍŠIL, L., PAŇKO, V. Selecting an optimal structure of artificial neural networks for characterizing rf semiconductor devices. In *Proceedings of the 53rd IEEE International Midwest Symposium on Circuits and Systems* (2010), Piscataway: IEEE, pp. 1206–1209. **50%**
- [6] DOBEŠ, J., PAŇKO, V., POSPÍŠIL, L. Accurate gate-delay model for high speed digital and analog circuits. In *Proceedings of the 2008 IEEE Dallas Circuits And Systems Workshop (DCAS)* (2008), Piscataway: IEEE, pp. 46–49. **33%**

- [7] DOBEŠ, J., POSPÍŠIL, L. Improving the accuracy of phemt models using corrective artificial neural networks. In *PIERS 2007 Prague - Proceeding od Progress In Electromagnetics Research Symposium [CD-ROM]* (2007), The Electromagnetics Academy, pp. 512–515. **50%**
- [8] DOBEŠ, J., POSPÍŠIL, L. Modeling special high frequency devices using artificial neural networks. In *Proceedings of the 2007 International Semiconductor Device Research Symposium [CD-ROM]* (2007), Piscataway: IEEE. **50%**
- [9] DOBEŠ, J., POSPÍŠIL, L. Accurate modeling of the special microwave structures using artificial neural networks. In *The 13th IEEE Mediterranean Electrotechnical Conference - MELECON 2006 - Electronic Proceedings [CD-ROM]* (2006), Piscataway: IEEE, pp. 1–4. **50%**
- [10] DOBEŠ, J., POSPÍŠIL, L. Using the artificial neural networks for accurate rf devices modeling. In *AEE'05 - Proceedings of the 4th WSEAS International Conference on: Applications of Electrical Engineering*, pages 139–143. WSEAS Press, 2005. **50%**
- [11] DOBEŠ, J., POSPÍŠIL, L. Exclusive and corrective artificial neural networks for accurate modeling the rf semiconductor devices. In *Proceedings of the Third IASTED International Conference on Circuits, Signals, and Systems. Calgary: IASTED / Acta Press* (2005), IASTED / Acta Press, pp. 286–291. **50%**
- [12] DOBEŠ, J., POSPÍŠIL, L. Enhancing the accuracy of microwave element models by artificial neural networks. *Radioengineering* 13, 3 (2004), 7–12. **50%**

Patenty

Autor žádné nemá.

Publikace ostatní

- [13] POSPÍŠIL, L., DOBEŠ, J. YADAV, A. Accurate modeling of unusual electronic circuit elements with artificial neural networks. In *Proceedings of 2nd Conference on Circuits, Systems, Control, Signals* (2011), vol. 1, World Scientific and Engineering Academy and Society, pp. 150–155. **33%**

- [14] DOBEŠ, J. POSPÍŠIL, L., YADAV, A. Precise Characterization of Memristive Systems by Cooperative Artificial Neural Networks. In *SCIS-ISIS, Kobe, Japonsko* (2012), v tisku - konference. **33%**
- [15] DOBEŠ, J. POSPÍŠIL, L., YADAV, A. Precise Characterization of Memristive Systems by Cooperative Artificial Neural Networks. In *WCECS, San Francisco, USA* (2012), v tisku - kongres. **33%**

Seznam ostatních publikací

Publikace v impaktovaných časopisech

Autor žádné nemá.

Publikace v recenzovaných časopisech

Autor žádné nemá.

Publikace excerpované WOS

Autor žádné nemá.

Patenty

Autor žádné nemá.

Publikace ostatní

- [16] JEŽDÍK, P., DUŠEK, K., BREJCHA, M., HÁJKOVÁ, L., POSPÍŠIL, L. Možnost využití RTG a CT diagnostiky (ne)jen v elektrotechnice - 2. část. In *DPS Plošné spoje od A do Z 2012*, vol.5, 2012, no. 5, p. 62-63. ISSN 1804-4891. **20%**
- [17] JEŽDÍK, P., DUŠEK, K., BREJCHA, M., HÁJKOVÁ, L., POSPÍŠIL, L. Možnost využití RTG a CT diagnostiky (ne)jen v elektrotechnice - 1. část. In *DPS Plošné spoje od A do Z 2012*, vol.4, 2012, no. 4, p. 58-59. ISSN 1804-4891. **20%**

- [18] DUŠEK, K., POSPÍŠIL, L., JEŽDÍK, P., BREJCHA, M. Technologické vybavení laboratoří LVR na FEL ČVUT v Praze. In *DPS Plošné spoje od A do Z* 2011, vol.1, 2011, no. 3, p. 8-9. ISSN 1804-4891. **25%**
- [19] JEŽDÍK, P., POSPÍŠIL, L., DUŠEK, K., BREJCHA, M. Diagnostické vybavení laboratoří LVR na FEL ČVUT v Praze. In *DPS Plošné spoje od A do Z* 2011, vol.4, 2011, no. 4, p. 78-79. ISSN 1804-4891. **25%**

Citované publikace

- [20] DOBEŠ, J., POSPÍŠIL, L. Enhancing the accuracy of microwave element models by artificial neural networks. *Radioengineering* 13, 3 (2004), 7–12. (Web of Science IF = 0,503) **50%**

MEMON, N.M., AHMED, M.M, REHMAN, F. A Comprehensive Four Parameters I-V model for GaAs MESFET Output Characteristics. *SOLID-STATE ELECTRONICS*, 2007, vol. 51, no. 3, pp. 511–516. (Web of Science IF = 1,493)

MEMON, N.M., AHMED, M.M, REHMAN, F. Comparison of Nonlinear I-V Models for Submicron GaAs MESFET's Characteristics. In Proc. of 8th International Conference on Solid-State and Integrated Circuit Technology, Shanghai 2006, pp. 896–898. (IEEE Xplore 04098269)

MEMON, N.M. Modeling Techniques of Submicron GaAs MESFETs and HEMTs. Ph.D. Thesis, Department of Electronic Engineering, Faculty of Engineering and Applied Sciences, Muhammad Ali Jinnah University, Islamabad.

Jit, Satyabrata; Analytical Modeling of the Current (I)-Voltage (V) Characteristics of Sub-Micron Gate-Length Ion-Implanted GaAs MESFETs under Dark and Illuminated Conditions, Department of Electronic Engineering, Faculty of Engineering and Applied Sciences, Institute of Technology, Varanasi, India.

(článek je celkem citovaný čtyřikrát)

SUMMARY

At present, there are many various microwave structures for which their nonlinear models for CAD are necessary. We will focus on the use of analytical models of transistors MOSFET, and their accuracy and other ways to improve the accuracy. However, in the recent SPICE (PSpice) family programs, only a class of five types of MESFET model is available. You can go the way of improving the analytical models described here, but this improvement has its limits of accuracy. An accuracy of the proposed modification of the analytic model is assessed by extracting model parameters of the GaAs MESFET, AlGaAs/InGaAs/GaAs pHEMT, and InGaAs/InP avalanche photodiodes MO457/4. Therefore, further ways to achieve greater accuracy in the model the one hand and on the other hand, the maximum effort to avoid a difficult and challenging structure model. In the thesis, a method is suggested for modeling miscellaneous microwave structures by exclusive neural networks or by corrective neural networks working attached to a modified analytic model. For this purpose, can be used either alone neural network or the possibility of combining the well-known analytical model and the corrective neural network that corrects this analytical model, or several mutually cooperating neural networks. Mentioned variants there are more, but these three above are relatively simple and provide the desired results. Using neural network was made more accurate analytical model, both in its static and dynamic parts. First was an approximation of the output characteristics of AlGaAs / InGaAs / GaAs pHEMT transistor using only one neural network was then used and correction neural network. He was also identified characteristics of the transistor N-MESFET DZ71, which exhibit oscillations due to both the small number of measured points, sizes neuro model and its learning method. Also was an approxi-

mation based capacity SACM InGaAs / InP avalanche photodiodes MO457/4, again using only a single neural network. Furthermore, experiments carried out systematic analysis for optimal neural network structure and the optimum the number of neurons in each layer of the network. Experiments were performed on neural networks with four and five layers, which modeled the P-channel transistor and JFET 2N2498 AlGaAs / InGaAs / GaAs pHEMT transistor and I also HF Transistor pHEMT II (working frequency to 110GHz) with optimization of neuro model above, for a gradual reduction in the number of neurons. For this optimization was Bayesian regularization method is used for learning neuro model, providing information on effectively used free parameters, using the network „bottleneck”. The characteristics of this transistor was measured in Bologna, Italy, which is one of the few centers in Europe (Dr. Svevo Monacovi, MEC, University of Bologna a University of Ferrara), able to perform this measurement and obtained from [7]. Further, the Pt-TiO_{2-x} -Pt memristive system characteristic with an extraordinary (but typical) hysteresis is approximated by a set of cooperative artificial neural networks, because a single network is unable to characterize this especial element. This method was for the purpose in this paper proposed, Many network optimization performed from above, ie, gradually decreasing numbers of neurons. Our developed models using artificial neural networks were compared with existing analytical models (Curtice, Statz, Susman, and TOM TOM2 [TriQuint]).

RESUMÉ

V současné době existuje mnoho různých mikrovlnných struktur, pro které je potřebné mít jejich nelineární modely do simulačních systémů CAD. Zaměříme se zejména na použitelné analytické modely tranzistorů MESFET, a na jejich přesnost a na další možnosti zlepšení této přesnosti. Bohužel v moderních programech třídy SPICE (PSpice) je k dispozici pouze pět typů modelů tranzistorů MESFET. Lze jít cestou zlepšování používaných analytických modelů, které je zde uvedeno, ale toto zlepšování má své limity přesnosti. Přesnost navrhované modifikace analytického modelu je posuzována vzhledem k získaným parametrům modelu GaAs MESFET tranzistoru, AlGaAs/InGaAs/GaAs pHEMT tranzistoru a InGaAs/InP lavinové fotodiody MO457/4. Proto jsou hledány další možnosti pro dosažení větší přesnosti modelu na straně jedné a na druhé straně maximální snaze se vyhnout složité a náročné konstrukci modelu. V této práci jsou navrhovány metoda pro modelování různých mikrovlnných struktur s využitím umělých neuronových sítí, a různých variant metodiky tohoto modelování. K tomuto účelu lze využít buď pouze neuronovou síť nebo možnost kombinace známého analytického modelu a korekční neuronové sítě, která tento analytický model koriguje, nebo také několik navzájem spolupracujících neuronových sítí. Uvedených variant existuje více, ale tyto tři výše uvedené jsou relativně jednoduché a poskytují požadované výsledky. S využitím neuronové sítě bylo provedeno zpřesnění analytického modelu jak v jeho statické tak i dynamické části. Nejprve byla provedena aproximace výstupních charakteristik AlGaAs/InGaAs/GaAs pHEMT tranzistoru za použití pouze jedné neuronové sítě, poté byla použita i korekční neuronová síť. Byly také identifikovány charakteristiky tranzistor N-MESFET DZ71, jež vykazovaly oscilace vlivem jednak malého počtu naměřených bodů, velikostí neuro modelu a jeho

metodou učení. Také byla provedena aproximace závislosti kapacity SACM InGaAs/InP lavinové fotodiody MO457/4, opět za použití pouze jedné neuronové sítě. Dále byla experimentálně provedena systematická analýza pro získání optimální struktury neuronové sítě a optimálního počtu neuronů v jednotlivých vrstvách této sítě. Experimenty byly provedeny na neuronových sítích se čtyřmi a pěti vrstvami, které modelovaly P-kanálový tranzistor JFET 2N2498 a AlGaAs/InGaAs/GaAs pHEMT I tranzistoru a také na vysokofrekvenčním tranzistoru pHEMT II (pracující do frekvence 110GHz) s optimalizací neuro modelu shora, za postupného snižování počtu neuronů. Pro tuto optimalizaci byla použita metoda Bayesovské regularizace při učení neuro modelu, poskytující informaci o efektivně využitých volných parametrech, s využitím sítě s tzv. „úzkým hrdlem“. Charakteristiky k tomuto tranzistoru byly změřeny v italské Bologni (Dr. Svevo Monacovi, MEC, University of Bologna a University of Ferrara), což je jedno z mála pracovišť v Evropě schopno provést měření na takto vysokých frekvencích a získány z [7]. A dále, charakteristika Pt-TiO_{2-x}-Pt memristivního systému, která vykazuje své typické hysterezi chování, které je pro ni charakteristické je aproximován několika neuronovými sítěmi, protože jediná síť není schopna charakterizovat tento speciální prvek. Tato metoda byla pro tyto účely v této práci navržena, včetně provedených optimalizací sítě shora, tj. postupně se snižujícími počty neuronů. Poslední provedené systematické experimenty ukazují, že optimální strukturu sítě lze nalézt poměrně snadno, a nemělo by to být příliš složité. Námi vytvořené modely využívající umělé neuronové sítě byly porovnány s dosavadními analytickými modely (Curtice, Statz, Susman, TOM a TOM2 [TriQuint]).