

MIKROBANGŲ ĮTAISŲ MODELIAVIMAS,  
TAIKANT DIRBTINIŲ NEURONŲ TINKLUS

Andrius Katkevičius

Vilniaus Gedimino technikos universitetas  
El. paštas andrius.katkevicius@vgtu.lt

**Santrauka.** Nagrinėjamos dirbtinių neuronų tinklų taikymo galimybės mikrobangų įtaisams tirti. Apžvelgiami eksperimentiniai ir teoriniai darbai. Pateikiama apibendrinta informacija apie uždavinius, sprendžiamus taikant neuronų tinklus, problemas, kylančias dirbtinius neuronų tinklus taikant mikrobangų uždaviniams spręsti, ir problemų sprendimo būdus. Pateikiama bendra neuronų tinklų struktūra ir konkretūs neuronų tinklų naudojimo pavyzdžiai.

**Reikšminiai žodžiai:** mikrobangų įtaisai, neuronų tinklai, lėtinimo sistemos, iteraciniai skaičiavimai.

## Įvadas

Tobulėjant mikrobangų įtaisams vis aktualesne problema tampa sudėtingų modeliavimo ir kompiuterinio projektavimo sistemų kūrimas. Analizuojant mikrobangų įtaisus reikalingas pilnavertis elektromagnetinis imitatorius, galintis tiesiogiai išspręsti prietaisą apibūdinančias Maksvelo lygtis. Ieškant naujų mikrobangų įtaisų, kompiuterinio projektavimo algoritmų, kaip svarbiausi kriterijai įvardijami: tikslumas, kompiuteriniai resursai, laiko sąnaudos.

Šiuo metu mikrobangų prietaisai analizuojami remiantis įvairiais metodais. Plačiąja prasme jie skirstomi į analitinius ir skaitinius (Štaras *et al.* 2010). Taikant analitinius metodus kiekvieną kartą iš naujo susiduriama su problemomis sudarant sistemos matematinį modelį ir išvedant ribinių sąlygų lygtis (Štaras, Katkevičius 2010). Skaitiniai metodai yra lankstesni ir tikslūs, bet reikalauja didelių kompiuterinių resursų ir laiko (Pomarnacki *et al.* 2010). Ypač tai aktualu pakartotinai atliekant modelio analizę, parenkant vis kitus pradinius parametrus. Be to, taikant tradicinius metodus sunku spręsti atvirkštinį sintezės uždavinį, kai žinant elektrinius parametrus norima rasti sistemos geometrinius ar fizikinius parametrus. Šios problemos lėtina analizės procesą ir apriboja visą modeliavimo eigą.

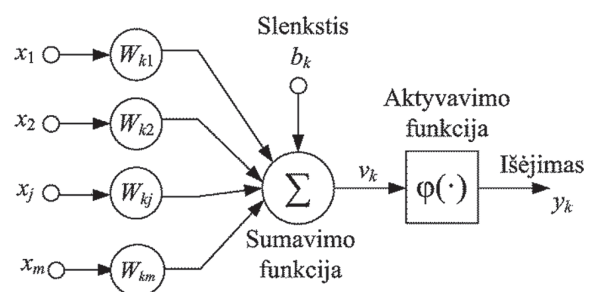
Pastaraisiais metais dirbtinių neuronų tinklų (DNT) metodai buvo pripažinti kaip naudinga alternatyva tradiciniams mikrobangų modeliavimo metodams (Kabir *et al.* 2010; Deh *et al.* 2006). DNT gali būti naudojami kuriant naujus modelius arba didinant esamų modelių tikslumą ir veikimo spartą, aproksimuojant bet kokią pasirinkto tiks-

lumo funkciją. Neuronų tinklo mokymas, prietaiso duomenimis, vyksta naudojant automatizuotą mokymo procesą, o išmokyti neuronų tinklai vėliau naudojami kaip spartūs ir tikslūs moduliai mikrobangų grandynams ir sistemoms projektuoti.

Šiame straipsnyje aptariame neuronų tinklų analizės metodus ir jų taikymą mikrobangų įtaisams modeliuoti.

## Neuronų tinklo struktūra

Neuronų tinklą sudaro atskirų neuronų visuma. 1 pav. pavaizduotas bendras neurono modelis, kuriame galima išskirti tris pagrindinius elementus: ryšių svorių vektorius, sumatorių ir aktyvavimo funkciją (Haykin 1999). Sumatorius sumuoja įėjimo signalus, padaugintus iš atitinkamų ryšių svorių. Aktyvavimo funkcija apriboja neurono išėjimo signalo amplitudę.



1 pav. Neurono modelis

Fig. 1. The model of a neuron

Neurono modelio slenkstis  $b_k$ , priklausomai nuo ženklo, keičia aktyvavimo funkcijos įėjimo signalo lygį. Neuronų tinklo veikimą nusako lygčių pora:

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (1)$$

$$y_k = \varphi(u_k + b_k), \quad (2)$$

čia  $x_1, x_2, x_j, x_m$  – įėjimo signalai;  $w_{k1}, w_{k2}, w_{kj}, w_{km}$  – neurono ryšių svoriai;  $b_k$  – slenkstis;  $\varphi(\bullet)$  – aktyvavimo funkcija;  $y_k$  – neurono išėjimo signalas.

Aktyvavimo funkcija gali būti įvairių tipų. Pagrindiniai iš jų yra slenkščio, rampos, sigmoidinės, hiperbolinio tangento. Neuronų tinklai skirstomi į vieno sluoksnio ir daugiasluoksnius. Vieno sluoksnio tinklas turi įėjimo ir išėjimo sluoksnius. Daugiasluoksnis neuronų tinklas papildomai turi tam tikrą nuo sprendžiamo uždavinio ir tinklo struktūros priklausantį paslėptųjų sluoksnių skaičių.

Neuronų tinklais susiejami daugiamaciai netiesiniai ryšiai tarp įvesties ir išvesties parametru, taikant (1) ir (2) išraiškas. Kuo didesnis neuronų skaičius įėjimo sluoksnyje, tuo lengviau neuronų tinklas susidoroja su daugiamaciais įvesties duomenimis. Didinant neuronų skaičių paslėptajame sluoksnyje efektyviau susidorojama su įėjimo signalų  $x$  ir išėjimo signalo  $y$  duomenų vektorių netiesiškumu, nei taikant aproksimavimą polinomu ar kitus aproksimavimo metodus.

### Neuronų tinklų taikymo moduliai

Dirbtinių neuronų tinklai taikomi tiesinio ir netiesinio įvertinimo, klasifikacijos, grupavimo uždaviniams spręsti. Priklausomai nuo sprendžiamos užduoties gali būti taikomi tiesioginio ir atvirkštinio modulio neuronų tinklai.

Tiesioginiu modeliavimu vadinamas analizės uždavinys, kai žinant ir į tinklo įėjimą siunčiant fizikinius arba geometrinius mikrobangų įtaisų parametrus tinklo išėjime siekiama rasti elektrinius parametrus. Paprastai sprendžiant analizės uždavinį įėjimai ir išėjimai susiejami ryšiu vienas su vienu (Tomar *et al.* 2010).

Atliekant atvirkštinį modeliavimą, t. y. sprendžiant projektavimo uždavinius, informacija siunčiama priešinga kryptimi – nustatomi fiziniai arba geometriniai parametrai, žinant elektrinius mikrobangų įtaisų parametrus (Kabir *et al.* 2008). Atvirkštinis uždavinys gali būti sprendžiamas dviem būdais: taikant optimizavimo arba tiesiogiai atvirkštinio modeliavimo metoda.

Taikant optimizavimo metoda pakartotinai siekiama nustatyti optimalius fizikinius ir geometrinius parametrus, kuriems esant tiksliai apskaičiuojami specifikacijose nurodyti elektriniai parametrai. Šis atvirkštinio modeliavimo metodas vadinamas sintezės metodu (Bellil *et al.* 2006; Watson *et al.* 1999).

Taikant tiesiogiai atvirkštinio modeliavimo metoda į neuronų tinklo įėjimą siunčiami elektriniai parametrai, o išėjime laukiami geometrinių arba fizikinių parametru rezultatai vienos iteracijos metu (Singh *et al.* 2011). Todėl šis metodas yra greitesnis nei optimizavimo metodas.

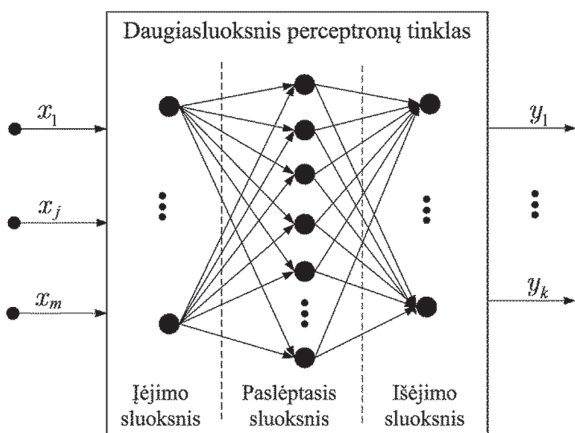
Siekiant nustatyti atvirkštinį modulį, mokymo proceso metu dažnai susiduriama su problema, kai nepavyksta rasti vieno unikalaus sprendimo, nes tos pačios įėjimo vertės susiejamos su daugeliu skirtingų sprendinių išėjime. Dėl šios priežasties neuronų tinklo mokymo procesas sudėtingėja, nes neuronų tinklas negali būti tiksliai išmokomas. Yra sugalvotas metodas, padedantis išvengti šios problemos, aptinkant mokomųjų duomenų pasikartojančius sprendinius (Kabir *et al.* 2008). Esant keletui unikalų sprendinių, duomenys sugrupuojami į grupes, taikant tiesioginį neuronų tinklo modulį taip, kad suformuotose atskirose duomenų grupėse nebūtų bendrų sprendinių. Remiantis gautomis nesikartojančiomis duomenų grupėmis sudaromi įvairūs atvirkštiniai moduliai, kurie taikomi visam moduliui sudaryti.

### Neuronų tinklų taikymo pavyzdžiai

Neuronų tinklų teorinis pagrindas pagrįstas universalioji priartėjimo teorija (Kabir *et al.* 2008), kuri teigia, kad neuronų tinklas su bent vienu paslėptuoju sluoksniu gali aproksimuoti bet kokią netiesinę netrūkiają daugiamatę funkciją bet koku norimu tikslumu. Neuronų tinklo modulio įvertinimas taip pat labai greitas. Dėl šių priežasčių neuronų tinklų metodai taikomi įvairiems mikrobangų įtaisams modeliuoti: bangolaidžių komponentams (Plonis *et al.* 2010); filtrams (Yahia *et al.* 2010; Michalski 2010); antenoms (Malathi *et al.* 2009); netiesiniams įtaisams modeliuoti (Schreurs *et al.* 2002); netiesiniams mikrobangų grandynams optimizuoti (Rizzoli *et al.* 2004).

Daugelyje mikrobangų įtaisų analizuojančių darbų neuronų tinklai taikomi juodosios dėžės pagrindu ir naudojamos elementarios neuronų tinklų struktūros, pavyzdžiui, daugiasluoksnis perceptronų tinklas su standartinėmis aktyvavimo funkcijomis. 2 pav. pateikta dažnai naudojama daugiasluoksnio perceptronų tinklo struktūra, turinti vieną paslėptąjį sluoksnį.

Remiantis nagrinėta literatūra, galima sudaryti du apibendrintus neuronų tinklų taikymo algoritmus tiesioginiam ir atvirkštiniam uždaviniams spręsti. Algoritmas taikomas mikrobangų įtaisams modeliuoti naudojant tiesioginį neuronų tinklo modulį. Taikant tradicinius analitinius ar skaitinius metodus surenkami mokomųjų duomenų masyvai. Sprendžiant modeliavimo uždavinius ieškoma sistemos ar įtaisų elektrinių parametru, žinant sistemos fizikinius ir geometrinius parametrus. Literatūroje iš aptartų modulių



**2 pav.** Daugiasluoksnio perceptronų tinklo struktūra, naudojama mikrobangų prietaisams modeliuoti

**Fig. 2.** The structure of a multilayer perceptron network used for simulating a microwave device

dažniausiai pasitaikantys sistemos geometriniai parametrai: sistemos ilgis, laidininkų ilgiai ir pločiai, laidininkų atstumai iki ekranų ir kiti. Sistemos fizikiniai parametrai: dažnis, santykinė dielektrinė skvarba ir kiti. Sistemos išėjime laukiami elektriniai parametrai: įtampa, srovė, įėjimo varža ir kiti (Katkevičius *et al.* 2012).

Mikrobangų įtaisų modeliavimo algoritmas
A. Įtaiso modelio pasirinkimas.
1. Įtaiso modelį apibūdinančių įvesties / išvesties parametrų parinkimas.
2. Pavyzdžių rinkimas, naudojant iteracinius arba skaitinius metodus.
B. Neuronų tinklo mokymas.
1. Interpoliavimas.
2. Įėjimų susiejimas su išėjimais.
3. Neuronų tinklo mokymas.
4. Tikrinimas.
C. Modeliavimas, taikant neuronų tinklus.
D. Rezultatų koregavimas.

Sprendžiant atvirkštinius sintezės uždavinius siekiama rasti sistemos geometrinis ir fizikinius parametrus, žinant elektrinius mikrobangų įtaisų parametrus (Donelli *et al.* 2006). Sintezės uždavinių sprendimo algoritmas panašus į pateiktąjį mikrobangų įtaisų modeliavimo algoritmą. Pagrindinis skirtumas tas, kad taikant sintezės algoritmą pakartotinai derinami įvesties kintamieji, kol pasiekiamas norimas išvesties parametrų tikslumas.


Mikrobangų įtaisams nagrinėti taikant dirbtinių neuronų tinklus dažniausiai siekiama nustatyti netrūkiąsias charakteristikas. Kai siekiama nustatyti trūkiąsias charakteristikas, susiduriama su papildomomis problemomis, nes standartinės slenksčio, ramos, sigmoidinė, hiperbolinio tangento aktyvavimo funkcijos nesugeba aproksimuoti trūkio taškų ir neuronų tinklas nemokomas ties trūkio

sritimis. Pavyzdžiui, 3 pav. pateiktas spiralinės, turinčios periodinių netolygumų, lėtinimo sistemos skersinis pjūvis ir spiralės vaizdas. Spiralinis laidininkas sudarytas iš dviejų periodiškai pasikartojančių vienalyčių sričių, besiskiriančių ilgiais  $l_1$  ir  $l_2$  bei banginių varžų vertėmis  $Z_1(0)$ ,  $Z_1(\pi)$ ,  $Z_2(0)$ ,  $Z_2(\pi)$  (Katkevičius *et al.* 2012).

4 pav. pateikti spiralinės lėtinimo sistemos lėtinimo koeficiento skaičiavimo rezultatai. Dėl periodinių netolygumų sistema įgauna užtvarinio filtro savybes ir lėtinimo koeficiento charakteristikose atsiranda trūkio taškai.

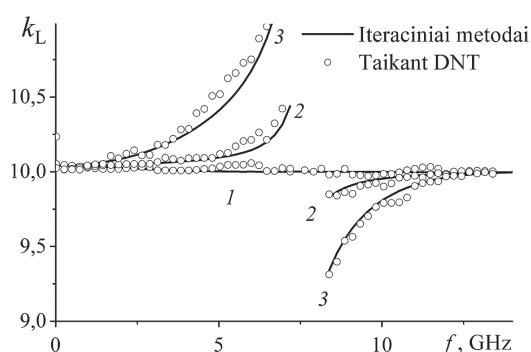
Analizuojant mikrobangų modelius, kurių dažninės charakteristikos yra trūkišios, nepakanka standartinių neuronų tinklų modelių. Vienas iš variantų yra naudoti kelių neuronų tinklų derinį. Kiekvienas neuronų tinklas mokomas dirbti tam tikroje dažninės charakteristikos dažnių juostoje. Tokiu būdu eliminuojami atsirandantys trūkio taškai (Katkevičius *et al.* 2012).

Kitu atveju reikalingos nestandartinės neuronų tinklų įėjimo ir paslėptojo sluoksnio neuronų aktyvavimo funkcijos, leisiančios aproksimuoti turinčias trūkių tiriamų sistemų charakteristikas.



**3 pav.** Spiralinės sistemos skersinis pjūvis (a) ir spiralės vaizdas (b): 1 – spiralė; 2, 3 – ekranai

**Fig. 3.** The cross-section of a helical system (a) and the view of the helix (b): 1 – helix; 2, 3 – shields



**4 pav.** Spiralinės sistemos lėtinimo koeficiento priklausomybės nuo dažnio ir  $l_1 + l_2 = 20$  mm,  $L = 2$  mm,  $l_1 = l_2 = 10$  mm.

- 1 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 40 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 40 \Omega$ ;
- 2 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 50 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 40 \Omega$ ;
- 3 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 50 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 30 \Omega$

**Fig. 4.** The factor of helical system retardation versus frequency at  $l_1 + l_2 = 20$  mm,  $L = 2$  mm,  $l_1 = l_2 = 10$  mm

- 1 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 40 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 40 \Omega$ ;
- 2 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 50 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 40 \Omega$ ;
- 3 –  $Z_1(0) = 60 \Omega$ ,  $Z_1(\pi) = 50 \Omega$ ,  $Z_2(0) = 50 \Omega$ ,  $Z_2(\pi) = 30 \Omega$

## Išvados

Ištirtos galimybės mikrobangų įtaisų modeliavimui ir projektavimui taikyti dirbtinius neuronų tinklus. Neuronų tinklų taikymas pasitvirtina tada, kai ieškant ryšių tarp atskirų parametrų sunku išvesti nagrinėjamojo modelio analitines išraiškas arba skaičiavimai reikalauja per daug resursų. Ryšių būtina ieškoti tarp viso modelio įvesties ir išvesties (tiesioginis neuronų tinklo modelis), tarp išvesties ir įvesties (inversinis modelis) arba tarp modelio dalies parametrų.

Neuronų tinklais pagrįsti modeliai yra spartūs ir lengvai įgyvendinami kompiuterinio modeliavimo programose. Dėl paprasto įėjimo ar paslėptojo sluoksnio neuronų papildymo neuronų tinklas lanksčiai susidoroja su įvairių matmenų ir įvairaus netiesiškumo laipsnio funkcijomis.

Sudėtingus uždavinius, kai mikrobangų įtaisų charakteristikos yra trūkiosios, reikia spręsti, naudojant kelių neuronų tinklų bendrą derinį arba taikant nestandartines ir kiekvienam mikrobangų įtaisui atskirai parenkamas aktyvavimo funkcijas.

## Literatūra

- Bellil, W.; Amar, C. B.; Alimi, A. M. 2006. Synthesis of wavelet filters using wavelet neural networks, *World Academy of Science, Engineering and Technology* 13: 108–111.
- Donelli, M.; Azaro, R.; Massa, A. 2006. Unsupervised synthesis of microwave components by means of an evolutionary-based tool exploiting, *Progress in Electromagnetics Research, PIER* 56: 93–108. <http://dx.doi.org/10.2528/PIER05010901>
- Deh, K.; Munshi, K.; Vempada, P., et al. 2006. The application of evolutionary artificial neural networks to microwave device modeling, *International Journal of Microwave and Optical Technology* 1(1): 68–74.
- Haykin, S. 1999. *Neural Networks: a Comprehensive Foundation*. Second edition. Prentice Hall. 842 p.
- Yahia, M.; Tao, J. W.; Benzina, H.; Abdelkrim, M. N. 2010. Ridged waveguide filter optimization using the neural networks and a modified simplex method, *International Journal of Innovation, Management and Technology* 1(3): 259–263.
- Kabir, H.; Zhang, L.; Yu, M., et al. 2010. Smart modeling of microwave devices, *IEEE Microwave Magazine* 11(3): 105–117. <http://dx.doi.org/10.1109/MMM.2010.936079>
- Kabir, H.; Yu, M.; Zhang, Q. 2008. Neural network inverse modeling and applications to microwave filter design, *IEEE Microwave Theory and Techniques* 56(4): 867–879. <http://dx.doi.org/10.1109/TMTT.2008.919078>
- Katkevicius, A.; Malisauskas, V.; Plonis, D.; Serackis, A. 2012. Calculations of characteristics of microwave devices using artificial neural networks, *Electrical Review* 1(a): 281–285.
- Michalski, J. J. 2010. Artificial neural networks approach in microwave filter tuning, *Progress in Electromagnetics Research* 13: 173–188. <http://dx.doi.org/10.2528/PIERM10053105>
- Malathi, P.; Kumar, R.; Patil, D. Y. 2009. Design of multilayer rectangular microstrip antenna using artificial neural networks, *International Journal of Recent Trends in Engineering* 2(5): 53–57.
- Plonis, D.; Mališauskas, V.; Serackis, A. 2010. Gyrotropic waveguides analysis based on the neural networks, *18th International Conference on Microwaves, Radar and Wireless Communications* 1–2: 508–511.
- Pomarnacki, R.; Krukonis, A.; Urbanavičius, V. 2010. Parallel algorithm for the Quasi-TEM analysis of microstrip multiconductor line, *Electronics and Electrical Engineering* 5(101): 83–86.
- Rizzoli, V.; Costanzo, A.; Masotti, D.; Lipparini, A.; Matri, F. 2004. Computer-aided optimization of nonlinear microwave circuits with the aid of electromagnetic simulation, *IEEE Trans. Microwave Theory Tech.* 52(1): 362–377. <http://dx.doi.org/10.1109/TMTT.2003.820898>
- Singh, J.; Singh, A. P.; Kamal, T. S. 2011. Design of circular microstrip antenna using artificial neural networks, *Proceedings of the World Congress on Engineering* 2(1): 9–12.
- Schreurs, P.; Verspecht, J.; Vandenberghe, S.; Vandamme, E. 2002. Straightforward and accurate nonlinear device model parameter-estimation method based on vectorial large-signal measurements, *IEEE Trans. Microwave Theory Tech.* 50(10): 2315–2319. <http://dx.doi.org/10.1109/TMTT.2002.803427>
- Štaras, S.; Martavičius, R.; Skudutis, J.; Urbanavičius, V.; Daškevičius, V. 2010. *Plačiajuosčių lėtinimo įtaisų modeliavimas ir taikymas*. Vilnius: Technika. 442 p.
- Štaras, S.; Katkevičius, A. 2010. Properties of helical structures containing periodical inhomogeneities, *Electronics and Electrical Engineering* 3(99): 49–52.
- Tomar, G. S.; Kushwah, V. S.; Saxena, S., et al. 2010. Design of microstrip filters using neural network, *Communication Software and Networks* 2: 568–572.
- Watson, P. M.; Cho, C.; Gupta, K. C. 1999. Electromagnetic-artificial neural network model for synthesis of physical dimensions for multilayer asymmetric coupled transmission structures, *International Journal of RF and Microwave Computer-Aided Engineering* 9: 175–186. [http://dx.doi.org/10.1002/\(SICI\)1099-047X\(199905\)9:3<175::AID-MMCE4>3.0.CO;2-P](http://dx.doi.org/10.1002/(SICI)1099-047X(199905)9:3<175::AID-MMCE4>3.0.CO;2-P)

## MODELLING MICROWAVE DEVICES USING ARTIFICIAL NEURAL NETWORKS

### A. Katkevičius

#### Abstract

Artificial neural networks (ANN) have recently gained attention as fast and flexible equipment for modelling and designing microwave devices. The paper reviews the opportunities to use them for undertaking the tasks on the analysis and synthesis. The article focuses on what tasks might be solved using neural networks, what challenges might rise when using artificial neural networks for carrying out tasks on microwave devices and discusses problem-solving techniques for microwave devices with intermittent characteristics.

**Keywords:** microwave devices, neural networks, retardation systems, iterative calculations.