



УНИВЕРЗИТЕТ У БЕОГРАДУ
ФИЗИЧКИ ФАКУЛТЕТ



Мр Катарина (Љубиша) Ђорђевић

**ПРИМЕНА НЕУРОНСКИХ МРЕЖА У
ФОТОАКУСТИЧКОЈ АНАЛИЗИ
СИЛИЦИЈУМА n-ТИПА У
ФРЕКВЕНТОМ ДОМЕНУ**

ДОКТОРСКА ДИСЕРТАЦИЈА

Београд, 2020.



UNIVERSITY OF BELGRADE
FACULTY OF PHYSICS



M.Sc. Katarina (Ljubiša) Đorđević

**APPLICATION OF NEURAL
NETWORKS IN PHOTOACUSTIC
ANALYSIS OF n-TYPE SILICON IN
FREQUENCY DOMAIN**

DOCTORAL DISSERTATION

Belgrade, 2020.

Ментор и члан комисије:

др Драган Маркушев, научни саветник
Институт за физику Земун-Београд
Универзитет у Београду

Чланови комисије :

др Слободанка Галовић, научни саветник
Институт за нуклеарне науке „Винча“
Универзитет у Београду

др Горан Попарић, редовни професор
Физички факултет
Универзитет у Београду

др Мићо Митровић, редовни професор
Физички факултет
Универзитет у Београду

др Едиб Добарџић, ванредни професор
Физички факултет
Универзитет у Београду

Датум одбране: _____

Захвалница

Захваљујем се ментору, др Драгану Маркушеву, научном саветнику Института за Физику, Земун-Београд, Универзитета у Београду на иницијалној идеји, указаном поверењу, подршци, стрпљењу, свесрдној помоћи при писању ове дисертације, без чијих корекција она не би имала ову форму.

Изузетно сам захвална др Слободанки Боби Галовић, научном саветнику ИНН „Винча“ Универзитета у Београду на подршци, искрености, несебичној стручној помоћи, великом залагању и активном учешћу у изради ове докторске дисертације. Велику захвалност дугујем и др Жарку Ћојбашићу, редовном професору Машинског Факултета Универзитета у Нишу без чијег ангажовања не би била могућа израда ове тезе.

Захваљујем се др Марици Поповић, научном сараднику ИНН „Винча“ на корисним саветима, дискусијама и указаној помоћи у изради тезе. Захваљујем се др Михаилу Рабасовићу, вишем научном сараднику, Института за Физику, Земун-Београд на конструктивним дискусијама током експерименталног рада. Захваљујем се др Миољубу Нешићу, научном сараднику ИНН „Винча“ на саветима и сугестијама у обради експерименталних резултата и размени мишљења током израде тезе. Захваљујем се др Младени Лукић доценту Факултета Заштите на раду, Универзитета у Нишу на корисним саветима и размени мишљења током израде тезе. Захваљујем се мр Мирослави Јордовић-Павловић, докторанту Факултета техничких наука Универзитета у Новом Саду, на корисним саветима и помоћи око савлађивања стручне терминологије из области вештачке интелигенције. Овим путем се захваљујем и Драгани Маркушев, докторанту Електронског факултета Универзитета у Нишу, на бодрењу и несебичној помоћи око разумевања ефекта везаних за полупроводнике.

Захвалност дугујем и др Горану Попарићу, др Мићи Митровићу и др Едибу Добарцићу професорима Физичког факултета Универзитета у Београду на интересовању и помоћи око израде докторске тезе.

Највећу захвалност дугујем мојој деци, Павлу и Алекси, што је љубав према науци и истраживањима расла заједно са њима. Захваљујем се родитељима, Бригити и Љубиши, на несебичној љубави и вери у мој успех, мојој сестри Јелени на великом разумевању, брату Влади на саветима током студија.

На крају се захваљујем свима онима који су на било који начин допринели да се израда ове дисертације доведе до краја.

Катарина Ћорђевић

САЖЕТАК

Формиране су и анализиране три неуронске мреже чији је циљ истовремено одређивање основних физичких параметара полупроводника користећи фреквентно модулисан фотоакустички сигнал. Обука, тестирање и валидација неуронских мрежа извршена је помоћу амплитуда и фаза фотоакустичког сигнала које одговарају експерименталној поставци отворене фотоакустичке ћелије. Амплитуде и фазе су израчунате применом теоријског модела композитног клипа прилагођеног полупроводницима. Симулација сигнала је урађена у фреквентном домену од 20Hz до 20kHz коришћењем ограниченог опсега промена коефицијената термалне дифузивности и термалног ширења, заједно са дебљином узорка. Показано је да најбоље карактеристике имају неуронске мреже са једним скривеним слојем и нормализованим подацима на улазу и излазу, обучаване симултано са амплитудама и фазама. Развијене мреже су примењене у обради експерименталних резултата мерења узорка силицијума n-типа. Испитивана је прецизност и поузданост мрежа у предикцији параметара, као и брзина обраде експерименталних података. Посебна пажња посвећена је прилагођавању обуке мреже експерименталним условима секвенцирањем улазних података и додавањем шума. Развијена је мрежна методологија контроле експерименталне поставке у односу на оптичке карактеристике извора зрачења и стање површина узорка. Добијени резултати показују да је фотоакустика, у спрези са применом неуронских мрежа, конкурентна техника којом се прецизно, поуздано и у реалном времену може извршити предикција тражених параметара полупроводника у фреквентном домену, уз активну контролу експерименталних услова.

Кључне речи: полупроводници, фототермални, фотоакустика, термална расподела, вештачке неуронске мреже, експериментални сигнал, инверзни проблем, силицијум n-типа, процедура повратка уназад, Гаусов случајни шум.

Научна област: Физика

Ужа научна област: Физика кондензованог стања

UDK број: 538.9(043.3) 537.311.322:534 (043.3)

ABSTRACT

Three neural networks were formed and analyzed, aiming to simultaneously determine the basic physical parameters of a semiconductor using a frequency modulated photoacoustic signal. Training, testing and validation of neural networks were performed using amplitudes and phases of the photoacoustic signal corresponding to the experimental set-up of an open photoacoustic cell. Amplitudes and phases were calculated using a theoretical model of a composite piston adapted to semiconductors. Signal simulations were performed in the frequency range from 20Hz to 20kHz using a limited range of changes in coefficients of thermal diffusivity and thermal expansion, together with sample thickness. It was shown that the best characteristics have networks with one hidden layer and normalized data at the input and output, trained simultaneously with amplitudes and phases. The developed networks were applied in the processing of experimental measurement results of n-type silicon samples. The accuracy and reliability of networks in parameter prediction were examined, as well as the processing speed of experimental data. Special attention is paid to adapt network training to experimental conditions sequencing input data and adding noise. A network methodology for controlling the experimental setup in relation to the optical characteristics of the radiation source and the condition of the surfaces of the examined sample has been developed. The obtained results show that photoacoustics, supported by neural networks, is a competitive technique that can accurately, reliably and in real-time predict the required parameters of semiconductors in the frequency domain, with active control of experimental conditions.

Key words: semiconductors, photothermal, photoacoustic, thermal distribution, artificial neural networks, experimental signal, inverse problem, n-type silicon reverse-back procedure, Gaussian random noise.

Scientific field: Physics

Research area: Condensed matter physics

UDC number: 538.9(043.3) 537.311.322:534 (043.3)

Списак публикација:

1. *K. Lj. Djordjevic , D. D. Markushev, Ž. M. Čojbašić, et al. Photoacoustic Measurements of the Thermal and Elastic Properties of n-Type Silicon Using Neural Networks, *Silicon* 12, 1289–1300 (2020) [doi:10.1007/s12633-019-00213-6](https://doi.org/10.1007/s12633-019-00213-6)
2. M. I. Jordovic-Pavlovic, A. D. Kupusinac, K. Lj. Djordjevic *et al.* Computationally intelligent description of a photoacoustic detector. *Opt Quant Electron* **52**, 246 (2020). <https://doi.org/10.1007/s11082-020-02372-y>
3. *K. Lj. Djordjevic, S. P. Galovic, M. I. Jordovic-Pavlovic, M.I. *et al.* Photoacoustic optical semiconductor characterization based on machine learning and reverse-back procedure. *Opt Quant Electron* **52**, 247 (2020). <https://doi.org/10.1007/s11082-020-02373-x>
4. M. I. Jordovic-Pavlovic, D. D. Markushev, A. D. Kupusinac, A.D. *et al.* Deep Neural Network Application in the Phase-Match Calibration of Gas–Microphone Photoacoustics. *Int J Thermophys* **41**, 73 (2020). <https://doi.org/10.1007/s10765-020-02650-7>
5. *K. Lj. Djordjevic, D. D. Markushev, Ž. M. Čojbašić, S. P. Galović, Inverse problem solving in semiconductor photoacoustics by neural networks, INVERSE PROBL SCI EN, under review.
6. *K. Lj. Djordjevic, S. P. Galovic, M. I. Jordovic-Pavlovic, Z. M. Cojbasic, D. D. Markushev, Improvement of Neural Networks Applied to Photoacoustic Signals of Semiconductors With Added Noise, *Silicon*, under review.

*из дисертације

Конференције:

1. D. K. Markushev, M. N. Popovic, S. P. Galovic, K. Lj. Djordjevic, D. D. Markushev, J. Ordonez-Miranda, Steady-state temperature component within an n-type silicon plate illuminated with a laser beam of modulated intensity, ICPPP (2019), 20-th International Conference on Photoacoustic and Photothermal Phenomena, Moscow, Russia
2. M. N. Popovic, D. D. Markushev, M. I. Jordovic-Pavlovic, K. Djordjevic, V. Miletic, M. V. Nestic, S. P. Galovic, Influence of protection layer on photoacoustic response of polymer samples – theory and experiment, ICPPP (2019) Moscow, Russia
3. M. Nestic, M. Popovic, K. Djordjevic, V. Miletic, M. Jordovic-Pavlovic, D. Markushev, S. Galovic, Development and comparison of the techniques for solving the inverse problem in Photoacoustics, Machine Learning with Photonics Symposium (2019) Belgrade, Serbia
4. K. Djordjević, S. Galović, M. Jordović-Pavlović, M. Nešić, M. Popović, Ž. Čojbašić And D. Markushev, Neural Network Based Reverse-Back Procedure For Photoacoustic Electronic Characterization Of Semiconductors, The 20th Symposium on Condensed Matter Physics - SFKM 2019, Belgrade - Serbia
5. M. Jordović-Pavlović, A. Kupusinac, K. Djordjević, S. Galović, D. Markushev, M. Nešić and M. Popović, Computationally Intelligent Estimation Of Properties For Polymer Microphone Diaphragms By Photoacoustic Measurement, The 20th Symposium on Condensed Matter Physics - SFKM 2019, Belgrade – Serbia

6. V. Miletic, K. Djordjevic, M. Popovic, D. Milicevic, D. Markushev, S. Galovic And M. Nestic, Preparing And Monitoring Photoacoustic Response Measurements Of Two-Layer Plla Samples Of Different Crystallinity Levels, The 20th Symposium on Condensed Matter Physics - SFKM [2019](#), Belgrade – Serbia
7. V. Miletic, K. Djordjevic, D. Markushev, M. Popović, S. Galović, D. Miličević, M. Nešić, Priprema PLLA uzoraka i snimanje njihovog fotoakustičkog odziva. Tumačenje kroz model dvoslojnih struktura, 19th International Symposium INFOTEH-JAHORINA, 18-20 March ([2020](#))
8. D. Tasic, M. Milovancevic, K. Djordjevic, S. Galovic, Z. Dimitrijevic, B. Mitic, S. Glogovac, History of Artificial Intelligence and its application in nephrology, *Nephrology Dialysis Transplantation* 35 3 gfaa142.P1846, ERA-EDTA (2020) <https://doi.org/10.1093/ndt/gfaa142.P1846>

Списак слика

Слика 1. Основне компоненте апаратуре која се користи за фотоакустичку спектроскопију.....	7
Слика 2. Апаратура отворене фотоакустичне ћелије са Института за физику у Земуну, коришћена за фотоакустичка мерења у овој тези.....	8
Слика 3. Трансмисиона конфигурација отворене фотоакустичке ћелије.....	9
Слика 4. Апаратура у радном режиму а) детекције фотоакустичких сигнала и б) детекције шума.....	10
Слика 5. Термални клип.....	12
Слика 6. Механички клип.....	13
Слика 7. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{total}(f)$, са компонентама термодифузионом $\delta p_{TD}(f)$, термоеластичном $\delta p_{TE}(f)$ и плазмаеластичном $\delta p_{PE}(f)$ n-типа силицијума Si.....	14
Слика 8. Померај топлотног клипа дебљине $2\pi\mu_g$ за $\delta x(t)$ услед чега настаје промена притиска $\delta p(t)$ у ваздуху.....	22
Слика 9. Савијање узорка услед загревања за U_r у r правцу, и U_z у правцу z -осе.....	25
Слика 10. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{total}(f)$, са компонентама термодифузионом $\delta p_{TD}(f)$, термоеластичном $\delta p_{TE}(f)$ и плазмаеластичном $\delta p_{PE}(f)$ Si n-типа за дебљину $1000\mu\text{m}$	28
Слика 11. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{total}(f)$, са компонентама термодифузионом $\delta p_{TD}(f)$, термоеластичном $\delta p_{TE}(f)$ и плазмаеластичном $\delta p_{PE}(f)$ Si n-типа за дебљину $500\mu\text{m}$	28
Слика 12. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{total}(f)$, са компонентама термодифузионом $\delta p_{TD}(f)$, термоеластичном $\delta p_{TE}(f)$ и плазмаеластичном $\delta p_{PE}(f)$ Si n-типа за дебљину $100\mu\text{m}$	29
Слика 13. Симулиране амплитуде а) A и фазе б) ϕ укупног фотоакустичког $\delta p_{total}(f)$ (црна линија) и искривљеног експерименталног $S(f)$ сигнала (црвена линија) у функцији фреквенције модулације f . Електронски $H_{total}^e(f)$ и акустички $H_{total}^a(f)$ одзив експерименталних уређаја назначен је стрелицама.....	32
Слика 14. Веза неурона у живим системима.....	39
Слика 15. Структура вештачког неурона.....	39
Слика 16.а) Структура неуронске мреже састављене од повезаних неурона са више улаза и излаза, б) Вишеслојна неуронска мрежа.....	40
Слика 17. Амплитуде и фазе укупног фотоакустичког сигнала плазма дебелих узорака у зависности од модулационе фреквенце, са променом дебљине од 100 до $1000\mu\text{m}$	41
Слика 18. Амплитуде и фазе укупног фотоакустичког сигнала плазма танких узорака дебљине од 10 до $60\mu\text{m}$	42
Слика 19. Линије укупног фотоакустичког сигнала у фреквентном опсегу 20Hz - 20kHz за вредности коефицијента термалне дифузије $D_T = 9 \cdot 10^{-5} \text{m}^2 \text{s}^{-1}$ промењен у опсегу $\pm 10\%$ за силицијум дебљине $800\mu\text{m}$	42

Слика 20. Линије укупног фотоакустичког сигнала у фреквентном опсегу 20Hz-20kHz за вредности коефициента термалног ширења $\alpha_T = 2.6 \cdot 10^{-6} \text{ K}^{-1}$ промењен у опсегу $\pm 10\%$ за силицијум дебљине $800 \mu\text{m}$	43
Слика 21. Дијаграм који представља добијање једног излаза $\sigma(m_i)$ једног неурона када су улазни подаци укупни фотоакустички сигнал $\delta p_{\text{total}}(f)$ (амплитуда и фаза) коме су додељене вредности тежина (w_1, w_2, \dots, w_n) . Дејство сигмоидалне функције у скривеном слоју након додавања вредности прага θ_i^1	44
Слика 22. Неуронска мрежа за инверзно решавање фотоакустичког проблема. На улазном слоју су амплитуде и фазе, скривен слој има 50 неурона. Излазни слој су три параметара: термална дифузивност, експанзија и дебљина.....	46
Слика 23. Симулација ФА сигнала са којима је обучена НМ: а) амплитуде и б) фазе плазма дебелих узорака силицијума n-типа.....	56
Слика 24. Приказ неуронске мреже са једним скривеним слојем која је коришћена за обуку и тестирање амплитуда и фаза ФА сигнала силицијумских узорака.....	57
Слика 25. Симулација ФА сигнала са којима је обучена НМ: а) нормализоване амплитуде и б) фазе плазма дебелих узорака силицијума n-типа.....	58
Слика 26. MatLab Neural Fitting.....	59
Слика 27. Међусобна зависност параметра предикције неуронске мреже на 110 сигнала независног теста.....	59
Слика 28. MatLab18 са 144 неурона на улазном слоју, 50 неурона скривеног и 3 неурона излазног слоја, коришћен за ANN1.....	60
Слика 29. MatLab18 са 72 на улазном слоју, 50 неурона скривеног и 3 неурона излазног слоја, коришћен за ANN2 и ANN3.....	60
Слика 30. Обука НМ мрежа на основу смањења вредности mse са епохама обуке: а) ANN1, б) ANN2 и в) ANN3.....	61
Слика 31. Графици а) односа и б) разлика параметара D_T^{ANN} и α_T^{ANN} који смо добили од неуронске мреже и параметара D_T и α_T независног теста сигнала са којима се мрежа није обучавала. Пуна линија је коришћена за дифузивност D_T и испрекидана линија за коефициент термалног ширења α_T	63
Слика 32. График зависности а) односа и б) разлике промене коефициента термалне дифузије (црна крива), промена коефициента термалног ширења (црвена крива) и промене линеарне димензије узорка (плава крива) у зависности од дебљине узорка.....	64
Слика 33. Пример 5 фотоакустичких сигнала, амплитуде и б) фазе, са којима је тестирана неуронска мрежа, силицијума n-типа које нису у кораку обуке неуронске мреже.....	65
Слика 34. ФА сигнал добијен параметарима из предикције НМ који се састоји од а) амплитуде и б) фазе укупног ФА сигнала и његове компоненте за узорак дебљине $721 \mu\text{m}$ силицијум n-типа из Табеле 5.....	67
Слика 35. Фреквентна зависност: а) амплитуда и б) фаза експерименталних мерења фотоакустичких сигнала $S(f)$ (звездице) три узорка силицијума n-типа (дебљина $l_1=830 \mu\text{m}$, $l_2=417 \mu\text{m}$ и $l_3=128 \mu\text{m}$) и одговарајућих амплитуда и фаза очишћених сигнала $\delta p_{\text{total}}(f)$ (линија) добијених након уклањања инструменталних девијација.....	68
Слика 36. Фотоакустички сигнал $\delta p_{\text{total}}(f)$ а) нормализована вредност амплитуде $A_{\text{total}}(f)$ и б) вредност фазе $\varphi_{\text{total}}(f)$ добијених за три различите дебљине узорака l које су дате неуронским мрежама за предикцију.....	69

Слика 37. Фреквентна карактеризација укупног фотоакустичког сигнала силицијумског узорка n-типа са компонентама термодифузионом, термоеластичном и плазмаеластичном за параметаре узорка дебљине $l_1^{\text{ANN}}=829.98\mu\text{m}$, $D_T^{\text{ANN}}=9.0030\times 10^{-5}\text{m}^2\text{s}^{-1}$ и $\alpha_T^{\text{ANN}}=2.5995\times 10^{-6}\text{K}^{-1}$ добијених предикцијом неуронске мреже.....	71
Слика 38. Приказ фреквентне зависности тоталног фотоакустичког сигнала и три његове компоненте за узорак силицијума за вредности параметара предикције неуронске мреже $l_2^{\text{ANN}}=416.87\mu\text{m}$, $D_T^{\text{ANN}}=8.9994\times 10^{-5}\text{m}^2\text{s}^{-1}$ и $\alpha_T^{\text{ANN}}=2.5993\times 10^{-6}\text{K}^{-1}$	71
Слика 39. Катактеризација узорка силицијума у фреквентном домену, након предикције параметара неуронском мрежом $l_3^{\text{ANN}}=128.02\mu\text{m}$, $D_T^{\text{ANN}}=9.0093\times 10^{-5}\text{m}^2\text{s}^{-1}$ и $\alpha_T^{\text{ANN}}=2.5952\times 10^{-6}\text{K}^{-1}$. Карактеризација је дата фотоакустичким сигналом са термодифузионом, термоеластичном и плазмаеластичном компонентом.....	72
Слика 40. Процедура повратка уназад фотоакустичког сигнала одређеног предикцијом неуронске мреже до „правог“ експерименталног ФА одзива силицијумских узорака n-типа за одређивање коефициента апсорпције β^{RBP} и рафлексије γ_R^{RBP}	74
Слика 41.а) однос амплитуда и б) разлика ФА сигнала предикције НМ и “правог” сигнала.....	75
Слика 42. Корелација коефициента апсорпције β^{RBP} у зависности од дебљине l^{ANN} , дифузивности D_T^{ANN} и експанзије α^{ANN} добијених предикцијом ANN.....	76
Слика 43. Симулација фотоакустичког одзива (црна линија), и сигнал истог одзива са а и б) 0.5% и в и г) 5% Гаусовог случајног шума (црвена линија).....	78
Слика 44. Средња квадратна грешка mse (једн. 74), за тренинг, валидација и тест неуронске мреже трениране у а) 100 и б) 1000 епоха.....	79
Слика 45. Тренирање мреже са истом базом сигнала која има а) 5%, б) 1% в) 0.5% г) 0.1% д) 0.05% и њ) 0.01% Гаусовог случајног шума.....	80
Слика 46. Показује промену а) поузданости (performanse) мрежа и б) број епоха обуке мрежа трениране на ФА сигнаlima Si n-типа, ако се на улазним сигнаlima постави у одређеном проценту случајни Гаусов шум.....	81
Слика 47. Максимална релативна грешка предикције три параметра а) дифузивности D_T , б) експанзије α_T и в) дебљине l узорака неуронским мрежама (тренираних на различитим % случајног Гаусовог шума) на ФАС у корацима промене параметара (110 ФАС-црна линија) и ван корака промене параметара (22 ФАС-црвена линија).....	84
Слика 48. Приказ средњих релативних грешака (%), предикције параметара а) дифузивности D_T , б) експанзије α_T и в) дебљине узорка l неуронским мрежама са различитим нивоом шума за два теста: независног (110 ФАС– црна линија) и сигнала ван корака обуке мреже (22 ФАС – црвена линија).....	85
Слика 49. Релативне грешке (%) предикције при параметра а) термалне дифузивности D_T б) експанзије α_T и в) дебљине три узорка l , дебљине 830 μm (црна линија), 417 μm (црвена линија) и 128 μm (плава линија).....	86

Списак табела

Табела 1. Вредности параметра силицијума који су коришћени за фитовање, [2,47,51,54].....	57
Табела 2. Грешке неуронских мрежа, максимална (%) и средња (%) које се јављају при предикцији три параметара D_T , α_T и l са три различите неуронске мреже трениране а) амплитудама и фазама, б) амплитудама и в) само фазама фотоакустичких сигнала. Грешке су одређене за независни тест.....	62
Табела 3. Тест и предикција 22 фотоакустичка сигнала неуронском мрежом ANN1.....	65
Табела 4. Максимална (%) и средња (%) грешка за D_T , α_T и l , за 22 тест ФА сигнала.....	66
Табела 5. Параметри D_T^{ANN} , α_T^{ANN} и l^{ANN} добијени предикцијом различитих неуронских мрежа ANN1, ANN2 и ANN3. Апсолутне грешке које представљају разлику параметра добијених предикцијом и параметара D_T , α_T и l добијених стандарним ФА техникама. Релативне % грешке прорачунате према параметрима стандардних техника.....	70
Табеле 6. Коефициент апсорпције β^{RBP} и рефлексивности γ_R^{RBP} добијених у повратном поступку (RBP) са одговарајућом (%) релативном грешком. Дата је вредност апсорбанце као производ коефициента апсорпције и дебљине узорка $\beta^{RBP} l^{ANN}$	75
Табела 7. Перформансе и број епоха тренинга мрежа на ФА сигналима са одређеним % Гаусовог шума.....	81
Табела 8. Максималне и средње грешке у предикцији параметра D_T , α_T и l чистог ФА сигнала (110ФАС) неуронским мрежама добијених додавањем различитог степена случајног Гаусовог шума од 0.01% до 5% на улазним подацима.....	82
Табела 9. Максималне и средње релативне (%) грешке у предикцији параметра D_T , α_T и l чистих ФАС(110) сигнала у корацима обуке мреже, са мрежама добијених додавањем различитог степена случајног Гаусовог шума од 0.01% до 5% на улазним сигналима.....	82
Табела 10. Максимална и средња грешка предикције параметара чистих фотоакустичких сигнала (22) који су ван корака обуке, неуронским мрежама са одрђеним % случајног Гаусовог шума постављеног на улазну базу.....	83
Табела 11. Максимална и средња релативна (%) грешка предикције три параметара: дифузивности, експанзије и дебљине узорака неуронским мрежама (тренираних са одређеним % случајног Гаусовог шума) на фотоакустичким сигналима који су ван корака обуке.....	84
Табела 12. Релативна (%) грешка предикције неуронских мрежа (са одређеним % Гаусовог шума) експерименталних резултата за три узорка (Табеле 5).....	85

Списак скраћеница

ФА	Фотоакустика
ФАС	Фотоакустички сигнал
НМ	Неуронска мрежа
ТД	Термодифузија
ТЕ	Термоеластика
ПЕ	Плазмаеластика
СГШ	Случајни Гаусов шум
MLP	Вишеслојни перцептрон (енг. multilayer perceptron)
ANN	(енг.artificial neural network)
ANN1	(енг.artificial neural network trained with amplitudes and phases simultaneously)
ANN2	(енг.artificial neural network trained with amplitudes)
ANN3	(енг.artificial neural network trained with phases)
mse	средња квадратна грешка (енг.mean squared error)
RBP	(енг.reverse back procedure)

САДРЖАЈ

1. УВОД

1.1. Мотивација.....	1
1.2. Процена научног доприноса.....	2
1.3. Организација тезе.....	3

2. ФОТОАКУСТИКА И ПОЛУПРОВОДНИЦИ

2.1. Фотоакустички ефекат и развој фотоакустике чврстих тела.....	5
2.2. Експерименталне поставке фотоакустике.....	6
2.3. Теоријско симулациони модел фотоакустичког одзива полупроводника.....	11
2.3.1. Теорија композитног клипа.....	12
2.3.2. Укупан фотоакустички одзив полупроводника.....	14
2.3.3. Израчунавање концентрације фотогенерисаних носилаца.....	15
2.3.4. Израчунавање температурних расподела у полупроводнику.....	18
2.3.5. Термодифузиони сигнал.....	22
2.3.6. Термоелстични сигнал.....	24
2.3.7. Плазмаеластични сигнал.....	26
2.3.8. Укупан фотоакустички одзив полупроводника.....	27
2.4. Корекција фотоакустичког сигнала.....	30
Литература (Поглавље 2).....	33

3. НЕУРОНСКЕ МРЕЖЕ ЗА ИНВЕРЗНО РЕШАВАЊЕ ПРОБЛЕМА ФОТОАКУСТИЧКОГ ПРОБЛЕМА

3.1. Карактеристике неуронских мрежа.....	37
3.2. Анализа теоријског модела фотоакустичког одзива полупроводника и развој неуронске мреже за фотоакустику.....	41
3.2.1. Неуронске мреже у фотоакустици.....	43
3.2.2. Алгоритам обуке.....	45
3.3. Избор погодног модела неуронске мреже.....	49
3.3.1. Улазни слој.....	49
3.3.2. Скривени слој.....	51

3.3.3. Излазни слој.....	51
Литература (Поглавље 3).....	52

4. РЕЗУЛТАТИ И ДИСКУСИЈА

4.1. Обука мреже.....	55
4.1.1. Општи принципи.....	55
4.1.2. Одабир опсега вредности параметара.....	59
4.1.3. Одабир најпоузданије мреже.....	60
4.1.4. Тест поузданости одабране мреже.....	62
4.1.5. Тест мреже са различитим корацима промене параметара.....	64
4.1.6. Анализа термоеластичних и плазмаеластичних процеса у полупроводнику.....	66
4.2. Карактеризација експерименталних узорака – предикција параметара.....	67
4.3. Решавање инверзног проблема и анализа термоеластичних процеса.....	70
4.4. Контрола стабилности експеримента неуронским мрежама анализом оптичких карактеристика узорка.....	73
4.5. Генерализација неуронске мреже.....	77
4.5.1. Обука без шума.....	79
4.5.2. Обука са шумом.....	79
4.5.3. Анализа предикције излазних података.....	81
4.5.4. Тест са сигналима ван корака промене параметара.....	83
4.5.5. Тест са експерименталним сигналима.....	85
Литература (Поглавље 4).....	87

5. ЗАКЉУЧАК

5.1. Општа запажања.....	89
5.2. Правци даљих истраживања.....	90

1. УВОД

Фотоакустика и друге фототермалне методе се последњих четрдесетак година интензивно развијају и налазе све ширу примену у различитим областима науке, технике, медицине, електронике, фотонице, итд. Ове методе су недеструктивне, у највећем броју случајева бесконтактне и захтевају минималну или никакву припрему узорка за карактеризацију. Свим овим предностима требало би додати и чињеницу да се једним мерењем може добити сигнал, који зависи од великог броја својстава материјала: оптичких, топлотних, еластичних, електронских и других са њима повезаних својстава, што у принципу препоручује ове методе за свеобухватну примену у карактеризацији различитих материјала и уређаја. Са друге стране, могућност одређивања свих ових својстава је повезана са потешкоћама које носи решавање инверзног проблема. Инверзни проблем код модел-зависних метода подразумева развој оптималног теоријско-симулационог модела којим ће се одредити параметри повезани са својствима узорка. То је основни корак који ће омогућити описивање свих доминантних процеса који утичу на мерни резултат у датом опсегу. Инверзно решавање проблема спада у лоше постављене проблеме математичке физике због нелинеарности, нестабилности и често математички неједнозначних решења. На пример, код мултипараметарског модела могуће је добити више равноправних решења, али само једно решење одговара физици проблема. Да би се што лакше превазишли поменути проблеми последњих година се, у оквирима решавања инверзних проблема, све више и чешће примењује вештачка интелигенција.

1.1. Мотивација

Основна мотивација ове тезе јесте развој и примена вештачке интелигенције, машинског учења и неуронских мрежа у инверзном решавању фотоакустичког проблема са циљем превазилажења следећих проблема: времена које је потребно за процес прикупљања експерименталних података у фотоакустици, времена потребног за инверзно решавање фотоакустичког проблема, повећања броја својстава материјала која се могу одредити фотоакустичним мерењима и повећање тачности мерених својстава.

Крајњи циљ је успоставити нову методологију којом се обезбеђује да експериментални уређаји обрађују резултате у реалном времену, на начин који омогућава брзу карактеризацију материјала, посебно полупроводничких. Да би се тај циљ остварио

потребно је успоставити одређене методе оптималног коришћења неуронских мрежа помоћу надгледаног учења, јер су мреже конкурентне било којој методи фитовања.

Поред основног мотива постоје још и додатни мотиви за бављење овом темом. Први од њих је да се допринесе развоју гас-микрофонске фотоакустичке фреквентне методе као класичне методе, која се и данас користи за недеструктивну карактеризацију материјала, и омогућава одређивање топлотних и еластичних својстава уз минималну припрему за експеримент.

Други, додатни мотив је анализа, карактеризација и примена полупроводничких материјала који служе у формирању савремених уређаја и чине језгра наноелектронских кола и претварача.

Трећи мотив је повезан је са избором допираног силицијума због тога што он још увек има најширу примену и користи се за: прављење диода, транзистора, фотонапонских претварача, као носач танких филмова и нано структура за фотокаталитичкос процесе, у производњи интегрисаних кола, итд. Због тако широке примене, постаје веома важно развити недеструктивну методу карактеризације топлотних, еластичних, оптичких и електронских својстава силицијумских узорака различитог степена допирања.

Четврти додатни мотив је коришћење неуронских мрежа за анализу решења инверзног фотоакустичког проблема, којим се из фотоакустичког одзива као последице, одређују узроци његовог настајања.

За избор неуронских мрежа у инверзном решавању фотоакустичког проблема код полупроводника, значајно је искуство које постоји у примени неуронских мрежа код фотоакустике гасова. С обзиром да се на основу тог искуства показало да добро обучена неуронска мрежа даје прецизне и поуздане вредности за физичка својства гасова, и то у реалном времену, најлогичнији избор је био да се за инверзно решавање фотоакустичког проблема код *n*-допираног силицијума развије, обучи и примени слична или чак једноставнија неуронска мрежа.

1.2. Процена научног доприноса

Научни допринос у овом раду се највише огледа у следећем:

а) Развијен је најједноставнији модел неуронске мреже који се показао као веома ефикасан у карактеризацији силицијумских узорака дајући врло прецизне и поуздане предикције тражених топлотних, оптичких и механичких параметара у реалном времену - много брже од било које друге методе фитовања.

б) За разлику од стандардног приступа формирању неуронских мрежа, развијен је посебан приступ њене обуке, на великом сету теоријских података заснованих на моделима у оквиру фотоакустике. Оптимизацијом улазних и излазних вектора кроз нормализацију, секвенцијалност тј. строги распоред улазних тачака, и додавањем различитог нивоа шума постигнута је велика прецизност и поузданост у предикцији параметара узорака.

в) Показано је да се применом овако обучених неуронских мрежа може контролисати рад експерименталне поставке прецизном анализом улазних параметара везаних за оптичке карактеристике извора побуде и испитиваног узорка.

г) Показано је да овакав начин обуке и оптимизације неуронских мрежа може указивати на слабости теоријског модела фотоакустике кроз анализу грешака излазних параметара неуронских мрежа, што може указати на правце даљег развоја модела.

1.3. Организација тезе

Ова теза се састоји из пет поглавља.

У првом, уводном поглављу је дата јасна мотивација тезе: потреба за развојем тачне, прецизне и поуздане технике за решавање инверзног фотоакустичког проблема, којом се може истовремено одредити више физичких својстава полупроводника у реалном времену. Истакнуто је да досадашње искуство упућује на развој и примену неуронских мрежа у те сврхе. Наглашена је важност карактеризације силицијума због њихове широке примене у наноелектроници, фотоници и испитивању танких слојева, због чега су развој и примена неуронских мрежа у овом раду усмерени баш на карактеризацију допираних узорака силицијума.

У другом поглављу је укратко објашњена фотоакустичка фреквентна метода. Дат је опис отворене фотоакустичке ћелије и инструменталне поставке за мерење фреквентног фотоакустичког сигнала. Објашњена је теорија обраде експерименталних сигнала и начина анализе инструменталне дисторзије. Након тога је приказан теоријско симулациони модел који описује све најважније физичке процесе у полупроводнику изложеном дејству монохроматске електромагнетне побуде а који доводе до акустичког сигнала који снима микрофон. Теоријски модел је анализиран и на основу спроведене анализе створен је концепт неуронске мреже и начина њеног обучавања са циљем карактеризације топлотне дифузивности, коефицијента линеарног ширења полупроводника и прецизног одређивања његове дебљине.

У трећем поглављу је дат теоријски резултат: приказане су развијене неуронске мреже намењене карактеризацији полупроводника. Пре тога су у уводном делу поглавља

изложени основни принципи формирања неуронских мрежа, њихове обуке и тестирања. На крају су дискутовани методи оптимизације развијених неуронских мрежа за њихову примену у фотоакустичкој карактеризацији полупроводника.

У поглављу четири дат је приказ резултата примене развијених неуронских мрежа у карактеризацији силицијума на основу експериментално мерених фотоакустичких фреквентних одзива. Дискутована је њихова тачност и поузданост, као и брзина обраде експерименталних података. На основу разлике мрежних предикција и литературних података одређиване су оптичке карактеристике извора побуде и стања површина испитаних узорка. На крају је додавањем различитог нивоа шума оптимизована база улазних података неуронске мреже како би се што више прилагодила за рад са експерименталним фотоакустичким одзивом.

У поглављу пет дата су закључна разматрања, као и предложени правци будућих истраживања.

2. ФОТОАКУСТИКА И ПОЛУПРОВОДНИЦИ

Фотоакустика као део фототермалних наука базира се на фотоакустичком ефекту тј. ефекту претварања апсорбоване светлости у звук. Примена фотоакустике у карактеризацији полупроводничких материјала је почела упоредо са развојем експерименталних метода, и то је у последњих четрдесетак година значајна област истраживања [1-4]. Циљ ових истраживања јесте успостављање конкурентне експерименталне технике која омогућава што свеобухватнију карактеризацију и инжењеринг особина полупроводника и полупроводничких направа (пројектовање особина важних за дату примену). У развој фотоакустике спада развој теоријско-симулационих модела који описује све најутицајније физичке процесе који доводе до сигнала који се експериментално мери, развој техника за инверзно одређивање параметара теоријско-симулационог модела односно карактеристика испитиваног узорка и развој саме експерименталне поставке. Полазећи од добро дефинисане трансмисионе експерименталне поставке са хелијом минималне запремине и успостављеног теоријско-симулационог модела, тежиште истраживања у овој дисертацији је на примени неуронских мрежа како би фотоакустичка експериментална поставка постала конкурентнија другим методама.

2.1. Фотоакустички ефекат и развој фотоакустике чврстих тела

Када се неко чврсто тело изложи дејству електромагнетног зрачења из најширег спектра таласних дужина, које је модулисано по интензитету, део побудне енергије тело апсорбује а део апсорбоване енергије се различитим нерадијативним процесима унутар објекта претвара у топлоту. Овај ефекат загревања узорка назива се фототермални ефекат. Његова последица јесте промена термодинамичког стања узорка описаног притиском, густином и температуром. Услед тежње система да успостави термодинамичку равнотежу (Други закон термодинамике), долази до простирања промене термодинамичког стања (пертурбације) притиска, температуре и густине унутар физичког објекта и у његовој ближој околини. Ове промене стања доводе до феномена који могу да се детектују: варијација температуре на површинама објекта, промену у спектру инфрацрвеног зрачења узорка, појаву градијента оптичког индекса преламања унутар објекта и у његовој ближој околини, дефлексије површина објекта, појава звучних таласа у гасовитом окружењу узорка, итд. Уколико је загревање периодично, периодичне промене температуре, густине и притиска доводе до појаве фотоакустичког таласа у узорку и његовом најчешће гасовитом окружењу. Овај

ефекат настанка звука променом термалног стања услед осветљавања је основа фотоакустичког ефекта.


Фотоакустички ефекат је уочен још далеке 1880. године, приликом истраживања Александра Бела (Aleksander Graham Bell) и његовом раду на фотофону [5]. Наредних неколико година велики број научника је покушавао да објасни уочени ефекат, али без успеха [6]. Тек век касније, ефекат су објаснили Розенцвајг и Гершо (Allan Rosencwaig & Allen Gercho), и успоставили први теоријско симулациони модел као основу за развој фотоакустичких експерименталних техника [3,7-9]. Од тада, па све до данас, развијено је десетине експерименталних поставки у корак са развојем ласера, ласерских диода и лед диода, као и са развојем различитих акустичких сензора и претварача. Са друге стране, очекивани потенцијал фотоакустичких метода у карактерисању великог броја својстава различитих материјала и направа, од оптичких, топлотних, еластичних, електронских и многих других, довео је до примене ових техника у различитим областима. Циљ ових метода је испитивање разноврсних материјала попут метала, диелектрика, полупроводника, па све до полимера, полимерних нанокмозита и биолошких ткива [10-18]. Све ове примене захтевале су допуне и генерализације основног Розенцвајг-Гершоовог модела, и последично до развоја различитих математичких техника за обраду експерименталних резултата, са циљем експерименталног одређивања што већег броја физичких својстава испитиваног узорка и успостављања везе између структурно-геометријских карактеристика узорка са његовим физичким својствима.

2.2. Експерименталне поставке фотоакустике

Експерименталне поставке фотоакустике нагло су се развиле развојем ласера и LED диода као извора светлости и електрет микрофона као ефикасних претварача звучних у електричне сигнале. Без обзира на врсту детектора и извора светлости који се користи, основне компоненте апаратуре која се користи за фотоакустичку спектроскопију приказане су на слици 1, [19,20].

Извор светлости, било импулсни или модулисани, периодично загрева узорак фототермалним ефектом. Периодично загревање узорка праћено је експанзијом узорка и слоја гаса непосредно уз његову површину, што изазива периодичну промену притиска гаса у ћелији – тако настаје звучни талас тзв. фотоакустички талас који се детектује помоћу микрофона као фотоакустички сигнал. Сигнал са микрофона пропорционалан је амплитуди и фази фотоакустичког таласа који носе информације о термалним, оптичким, механичким

и електронским карактеристикама загрејаног узорка. У зависности од начина прикупљања фотоакустичких таласа можемо говорити о различитим експерименталним методама у фотоакустици. На основу положаја детектора у односу на извор светлости методе могу бити рефлексионе и трансмисионе [3,4,21-23]. На основу начина светлосне побуде методе делимо на импулсне и модулисане, а уколико се извор зрачења модулише на једној учестаности а мења се таласна дужина зрачења у широком опсегу, говоримо о методи фотоакустичке спектроскопије [24-26].




Слика 1. Основне компоненте апаратуре која се користи за фотоакустичку спектроскопију.

У оквиру ове тезе се користи трансмисиона фотоакустичка метода са фреквентно модулисаним извором зрачења на једној таласној дужини, тзв. конфигурација отворене фотоакустичке ћелије (open photoacoustic cell). Она је добро усклађена са развијеним теоријским моделима заснованим на једнодимензионалном провођењу топлоте у полупроводничким материјалима. Једна од таквих конфигурација, која је коришћена за потребе ове тезе, развијена је и налази се у Институту за физику у Земуну (слика 2)[27-29].

Апаратура је прилагођена мерењима фотоакустичких сигнала у фреквентном домену, а уз познавање инструменталног утицаја и шума на мерене сигнале представља добар основ за избор различитих методе обраде сигнала. Ефикасним препознавањем и уклањањем утицаја инструмената [30-36], детектора и пратеће електронике, омогућава се добијање „правих“ (без изобличења) експерименталних фотоакустичких сигнала, помоћу којих се може извршити прецизна карактеризација узорка употребом неуронске мреже.

Конфигурација отворене фотоакустичке ћелије подразумева да се микрофон као детектор фотоакустичког сигнала користи и као фотоакустичка ћелија на коју је директно наслоњен испитивани узорак. Тиме се постиже минимална запремина фотоакустичке ћелије

и избегава се слабење сигнала у односу на стандардне ћелије много веће запремине због тога што је сигнал обрнуто пропорционалан запремини. Сигнал који микрофон бележи окарактерисан је типичном амплитудно-фазном карактеристиком у фреквентном домену.



Слика 2. Апаратура отворене фотоакустичне ћелије са Института за физику у Земуну, коришћена за фотоакустичка мерења у овој тези.


Експеримент је прилагођен трансмисионим мерењима јер се акустички сигнали детектују на супротној страни од стране осветљавања узорка. Истовремено, експеримент је прилагођен једнодимензионалном транспорту енергије у узорку заснованом на Фуријеовом закону провођења топлоте (Fourier's Law of Heat Conduction). Једнодимензионални транспорт енергије се постиже хомогеним осветљавањем узорка и његовом специфичном геометријом облика кружне плочице (дебљином много мањом од осталих димензија). На овај начин се избегавају тродимензионални ефекти провођења топлоте.

Експериментална поставка (слика 3) [27-29] се састоји од детекционе јединице, побудне јединице и јединице за контролу и обраду сигнала. И детекциона и побудна јединица смештене су у кућишта направљена од дуралуминијума. Сам распоред јединица у фотоакустичкој ћелији је подешен тако да се постигне максимална акустична заштита од буке и да се добије добар однос сигнала и шума.

Побудну јединицу чини ласерска диода LED (XL7090-RED), снаге 10mW, модулисана струјним модулатором у опсегу фреквенција од 20Hz до 20kHz, контролисана осетљивом фотодиодом. Ласерска диода даје монохроматску светлост таласне дужине 660nm која припада црвеној светлости видљивог дела спектра. Светлост са диоде пролази кроз систем сочива којим се обезбеђује да се узорак осветљава хомогено по целој површини. Код примене LED и ласерских диода као извора светлости у градњи експерименталних уређаја за фотоакустику треба издвојити неке од њихових потенцијално повољнијих карактеристика у поређењу са конвенционалним изворима светлости: усмерена емисија

светлости; практичне димензије; отпорност на механичка оштећења (нпр, ломљење и слично); могућност врло брзог стављања у погон пуном снагом; велика способност модулације без штетних ефеката; способност рада и на ниским температурама; могућност рада у пригушеном режиму.

Правилним коришћењем и контролом јачине струје која пролази кроз LED и ласерску диоду могу се смањити топлотни ефекти који могу бити главни узрок флукуације интензитета емитоване светлости и смањења радног века диода. Све ове карактеристике доприносе испуњењу једног врло важног захтева експеримента а то је захтев за репродуцибилношћу (поновљивошћу) мерења. Ово се посебно односи на стабилност зрачења у смислу одржања таласне дужине и интензитета добијене светлости.




Слика 3. Трансмисиона конфигурација отворене фотоакустичке ћелије.

Детекциона јединица садржи електретски микрофон (ЕСМ 30В, JinInElectronicCo., Ltd.) који заједно са узорком чини фотоакустичку ћелију, слика 3. Пречник електретског микрофона је 9.8 mm, а његова осетљивост је око 2.5 mV/Pa. Због рада са малим интензитетима светлости, тј. малим побудама, сигнали са микрофона морају да се појачају десет или сто пута операционим појачавачима ОР37 са батеријским напајањем. Комплетна електроника и драјвери за контролу рада диоде и микрофона су направљени у Институту за физику. Рачунар са одговарајућим софтвером је основни део система за контролу и обраду сигнала. Главни део рачунара који се користи у мерењима је звучна картица (Intel 82801Pb/ir/ih hd) која симулира рад фазно-фреквентног тзв. lock-in појачивача. Сигнали са

микрофона и фотодиоде се доводе на звучну картицу преко два канала линијског стерео конектора.

За рад рачунара и извођење експеримента користи се софтвер који је написан, само за потребе ове апаратуре, у Microsoft Visual C++ 6.0. Програм има једноставан и разумљив интерфејс. Генерише сигнал за модулацију ласерске/LED диоде и врши прикупљање података. Користећи овај програм, могуће је променити фреквенцију и интезитет модулације светлосног извора, као и корак одабирања фреквенци. Такође, програм омогућава коректну симулицију lock-in појачавача користећи сигнал са фотодиоде као референтни.

Коришћена експериментална апаратура погодна је за рад у два различита режима (слика 4): а) детекцију фотоакустичких сигнала и б) детекцију шума. Разлика између ова два начина рада је само у томе што се за детекцију шума између извора светлости и узорка поставља непровидна препрека (blank или beam-block) како би се избегло осветљавање узорка, његово загревање и стварање звучних таласа [27-29].



Слика 4. Апаратура у радном режиму а) детекције фотоакустичких сигнала и б) детекције шума.

На овај начин може се измерити шум у нискофреквентном делу спектра који је типичан за микрофон, тзв. фликер шум (flicker noise), као и квази шум тј. кохерентна сметња (coherent signal deviation) који потиче од система за струјну модулацију а јавља се на вишим фреквенцијама. Снимање микрофонског шума и кохерентне сметње је врло битно како би се утврдио њихов утицај на мерене сигнале. Обично је у свим мерењима утицај микрофонског шума занемарљив, док кохерентна сметња утиче на облик укупног сигнала и мора бити прецизно измерена да би се ефикасно уклонила.

2.3. Теоријско симулациони модел фотоакустичког одзива полупроводника

Фотоакустика полупроводника се базира на анализи три главна ефекта који доводе до стварања звучног таласа: термодифузиони, термоеластични и плазмаеластични ефекат. Термодифузиони ефекат је одређен провођењем топлоте кроз супстанцу полупроводника и зависи од топлотне дифузивности самог материјала, што значи од топлотне проводности, густине и специфичне топлоте. Други ефекат је термоеластични ефекат који је одређен савијањем материјала које настаје због различитог степена загревања површина узорка који је осветљен са једне стране. Овај ефекат зависи од геометријских параметра узорка (дебљине, полупречника плочице) али и од његових топлотних карактеристика путем коефицијента термалног ширења који зависи од врсте материјала и промене његове температуре. Трећи ефекат је тзв. плазмаеластични ефекат, који се огледа у савијању узорка до кога долази услед различитог нивоа механичког стреса на осветљеној и неосветљеној страни узорка. Механички стрес настаје као последица интеракције фотогенерисаних слободних носилаца са чворовима кристалне решетке полупроводника. Овај ефекат зависи од електронских карактеристика материјала као што су: коефицијент електронске деформације материјала и концентрација фотогенерисаних носилаца [13,36-43].

Детекција звучног таласа помоћу микрофона представља детекцију амплитудно-фазних карактеристика сигнала које су веома осетљиве на промену параметара узорка као што су: густина, дебљина, полупречник, коефицијент топлотне проводљивости, коефицијент термалне дифузије, коефицијент линеарног ширења, специфична топлота, итд. Тиме се анализа карактеристика чврстог узорка своди на анализу амплитуда и фаза фотоакустичких сигнала у фреквентном домену. Методама фитовања на основу теоријског модела могу се одредити, у аналитичком и нумеричком смислу, сигнали који одговарају експерименталном мерењу, а који су дефинисани поменутиим параметрима узорка.

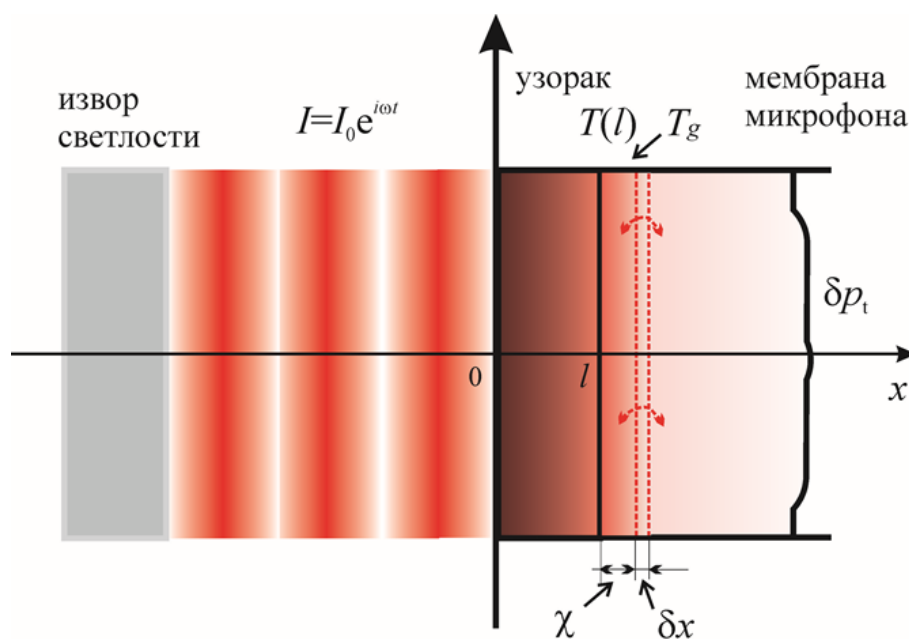
Одређивањем параметра узорака на основу експерименталног фотоакустичког сигнала омогућена је даља анализа различитих физичких процеса у самом узорку, која се састоји у томе да се пронађу њихове области доминације у задатим фреквентним доменима као и температурне расподеле како унутар узорка тако и на његовим површинама.

2.3.1. Теорија композитног клипа

Већину физичких величина које су приказане у овој тези представљаћемо у облику комплексних бројева ради једноставних математичких израчунавања. Увек треба имати у виду да физички смисао имају само реални делови тих комплексних величина. Апсорпцијом модулисаног зрачења $I = I_0(1 + e^{i\omega t})$ где је $\omega = 2\pi f$, са фреквенцијом модулације f долази до периодичног грејања полупроводника које настаје услед постојања конверзије апсорбоване енергије у топлоту дуж читавог узорка. Тиме се мења температурна расподела унутар узорка $T_s(x, f)$.

Температурна расподела, као сложена функција носилаца наелектрисуња као носилаца топлоте, условљава појаву термоеластичног савијања узорка. Периодичне промене температурних расподела доводе до појаве звучног таласа $\delta p_{\text{total}}(f)$ који је објашњен теоријом композитног клипа (Model of composite piston). Композитни клип се састоји из два клипа: термалног (t) $\delta p_t(f)$ и механичког (m) $\delta p_m(f)$ [4,44-50]. Ови клипови су последица периодичног кретања слоја гаса непосредно уз неосветљену површину полупроводничког узорка:


$$\delta p_{\text{total}}(f) = \delta p_t(f) + \delta p_m(f). \quad (1)$$



Слика 5. Термални клип

Компонента термалног клипа $\delta p_t(f)$ (thermal piston), настаје као последица периодичне промене температуре задње неосветљене површине узорка (слика 5, $T(l)$), услед чега се загрева слој ваздуха дебљине λ непосредно уз узорак. Тај слој ваздуха се шири и скупља у ритму промене температуре на неосветљеној страни узорка $T(l)$. На тај начин се мења дебљина слоја ваздуха за вредност δx што доводи до адијабатске промене ($pV^\gamma = const$) притиска у гасној колони која се преноси од узорка до мембране микрофона. Компонента термалног клипа је тако одређена ефектима термалне дифузије - ТД (транспорта енергије) у узорку, тако да можемо увести ознаку за ову компоненту $\delta p_{TD}(f)$ [2,27,36-44].

Компонента механичког клипа $\delta p_m(f)$ (mechanical piston), настаје као периодична промена притиска у ваздушном слоју око узорка као последица његовог механичког савијања (слика б). Ова компонента механичког клипа може да настане због два разлога: а) различитих загрејаности предње и задње стране узорка која изазива еластично савијање узорка и формирање термоеластичне – ТЕ компоненте промене притиска $\delta p_{TE}(f)$ и б) неједнаке концентрације фотогенерисаних носилаца предње и задње стране узорка које доводе до савијања узорка и формирања тзв. плазма еластичне - ПЕ компоненте $\delta p_{PE}(f)$ [2,27,44-51].



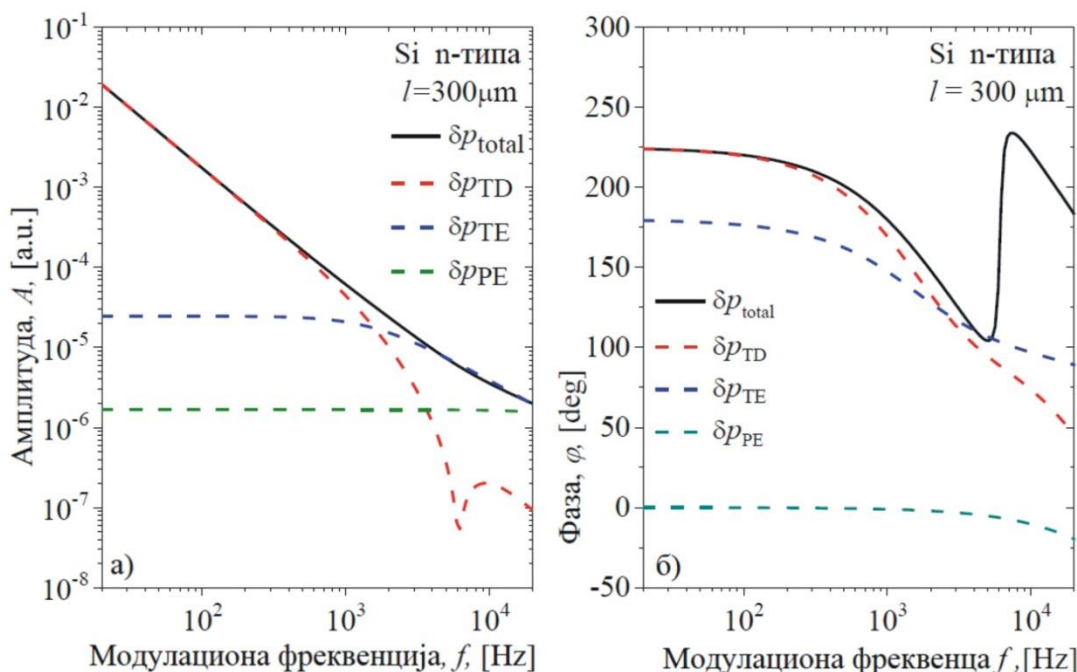
Слика 6. Механички клип

2.3.2. Укупан фотоакустички одзив полупроводника

Узевши у обзир теорију композитног клипа (1), можемо написати да је $\delta p_i(f) = \delta p_{TD}(f)$ и $\delta p_m(f) = \delta p_{TE}(f) + \delta p_{PE}(f)$, тако да се укупан фотоакустички сигнал у фреквентном домену који одговара фотоакустичком одзиву осветљеног полупроводника може написати у облику:

$$\delta p_{total}(f) = \delta p_{TD}(f) + \delta p_{TE}(f) + \delta p_{PE}(f) \quad (2)$$

где су термодифузиона и термоеластична тзв. термалне компоненте укупног фотоакустичког сигнала јер су температурно зависне, док је плазмаеластична тзв. електронска компонента која не зависи од температуре већ од расподеле концентрације фотогенерисаних носилаца. Ова формула је дата у оквирима Мекдоналд-Ветселовог модела композитног клипа [4,37,38] (McDonald-Wetsel composite piston model).



Слика 7. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{total}(f)$, са компонентама термодифузионом $\delta p_{TD}(f)$, термоеластичном $\delta p_{TE}(f)$ и плазмаеластичном $\delta p_{PE}(f)$ n-типа силицијума Si.

Промена притиска у фотоакустичкој ћелији микрофона, настала као последица формирања композитног клипа, узрокује настанак фотоакустичког сигнала $\delta p_{total}(f)$

(једначина (2)) који се детектује микрофоном, а који се може представити као комплексна величина изразом:

$$\delta p_{\text{total}}(f) = A(f)e^{i\varphi(f)}, \quad (3)$$

где су: $A(f)$ амплитуда и $\varphi(f)$ фаза укупног фотоакустичког сигнала. Типичан изглед $\delta p_{\text{total}}(f)$ добијеног помоћу једначина (2) и (3) приказан је на слици 7.

2.3.3. Израчунавање концентрације фотогенерисаних носилаца

Из литературе је добро познато да допирани полупроводници садрже већинске и мањинске носиоце. У случају полупроводника n -типа, већински носиоци су електрони концентрације n , а мањински шупљине концентрације p . Осветљавањем полупроводника светлошћу одговарајуће таласне дужине генерише се одређена концентрација фотогенерисаних носилаца, подједнако електрона (δn_n) и шупљина (δn_p). Код допираних полупроводника увек је $n \gg \delta n_n$ и $\delta n_p(x, f) \gg p$. Одатле видимо да је промена већинских носилаца приликом осветљавања узорака занемарљива, а да је промена мањинских носилаца значајна. Због тога читаву динамику фотогенерисаних носилаца у полупроводнику описујемо динамиком фотогенерисаних мањинских носилаца [52-58]. У нашем случају су то шупљине чију динамику описујемо променама δn_p .

Да би поједноставили анализу фотогенерисаних носилаца, у оквирима ове тезе користићемо полупроводничке кружне плочице (као што смо већ напоменули у поглављу 2.2.) које имају цилиндричну симетрију. Кроз плочице се посматра дифузија фотогенерисаних носилаца и топлоте само у једином правцу, а занемарује се дифузија у осталим правцима. Утицај околног ваздуха на апсорпцију светлости и размена топлоте између плочица и ваздуха су процеси који се сматрају занемарљивим.

Претпоставимо да се полупроводник n -типа осветљава са једне стране модулисаном светлошћу интензитета $I = I_0(1 + e^{i\omega t})$ (I_0 је интензитет извора светлости, $\omega = 2\pi f$ где је f фреквенција модулације). Уколико је енергија апсорбоване светлости $\varepsilon = h\nu$ већа од енергије процепа полупроводника ε_g , долази до генерације вишка носилаца чија се концентрација периодично мења на начин $\delta n_p(x, t) = \delta n_p(x)(1 + e^{i\omega t})$, где је $\delta n_p(x)$ просторна расподела концентрације носилаца у полупроводнику.

Транспорт фотогенерисаних носилаца се у полупроводнику може посматрати као дифузиони процес дуж осе нормалне на осветљену површину узорка и описује се једнодимензионалном дифузионом једначином датом у облику:

$$\left(\frac{\partial^2}{\partial x^2} - \frac{1}{D_p} \frac{\partial}{\partial t} \right) \delta n_p(x, t) = -\frac{1}{D_p} (G - R), \quad (4)$$

где је коефициент D_p дифузивност носилаца, G представља члан који описује генерацију (стварање) фотогенерисаних носилаца који се јављају услед директне апсорпције светлости, а R описује смањење њихове концентрације услед процеса рекомбинације [46,50,51]. G и R су дати изразима:

$$G = \frac{I}{2} \frac{1 - \gamma_R}{h\nu} \beta e^{-\beta x} \quad \text{и} \quad R = \frac{\delta n_p(x, t)}{\tau_p} \quad (5)$$

где је β апсорпциони коефициент узорка, γ_R рефлексивност површине узорка и τ_p је време живота носилаца. Изрази G и R из једначина (5), се могу раздвојити на статички и динамички део:

$$G = G(x) + G(x, t) = \frac{I_0}{2} \frac{1 - \gamma_R}{h\nu} \beta e^{-\beta x} + \frac{I_0}{2} \frac{1 - \gamma_R}{h\nu} \beta e^{i\omega t - \beta x}, \quad (6)$$

$$R = R(x) + R(x, t) = \frac{1}{\tau_p} \delta n_p(x) + \frac{1}{\tau_p} \delta n_p(x) e^{i\omega t}, \quad (7)$$

где смо у једначини (6) искористили: $I = I_0(1 + e^{i\omega t})$, а у једначини (7) смо искористили да је $\delta n_p(x, t) = \delta n_p(x)(1 + e^{i\omega t})$. Заменом једначина (6) и (7) у једначину (4) могу се добити следеће две дифузионе једначине. Прва једначина, која описује статичку расподелу концентрације фотогенерисаних носилаца у узорку:

$$\left(\frac{d^2}{dx^2} - \frac{1}{D_p \tau_p} \right) \delta n_p(x) = -\frac{I_0}{2D_p} \frac{1 - \gamma_R}{h\nu} \beta e^{-\beta x}. \quad (8)$$

Ова једначина није од интереса у нашем разматрању јер не утиче на формирање фотоакустичког таласа [2,58-59]. Друга једначина, описује динамичку расподелу фотогенерисаних носилаца у осветљеном полупроводнику:

$$\left(\frac{\partial^2}{\partial x^2} - \frac{1}{D_p} \frac{\partial}{\partial t} \right) \delta n_p(x) e^{i\omega t} = -\frac{I_0}{2D_p} \frac{1-\gamma_R}{h\nu} \beta e^{i\omega t - \beta x} + \frac{1}{D_p \tau_p} \delta n_p(x) e^{i\omega t}, \quad (9)$$

која је од интереса у овом раду јер утиче на стварање фотоакустичких таласа. Fourie-овом трансформацијом, једначина (9) постаје:

$$\left(\frac{d^2}{dx^2} - \frac{i\omega}{D_p} - \frac{1}{D_p \tau_p} \right) \delta n_p(x, \omega) = -\frac{I_0}{2D_p} \frac{1-\gamma_R}{h\nu} \beta e^{-\beta x}. \quad (10)$$

Ако уведемо смену $L = L_p / \sqrt{1+i\omega\tau_p}$, где је L комплексна дифузиона дужина мањинских носилаца а $L_p = \sqrt{D_p \tau_p}$ је дифузиона дужина мањинских носилаца, уз $\omega = 2\pi f$ где је f фреквенција модулације, једначина (10) постаје:

$$\left(\frac{d^2}{dx^2} - \frac{1}{L^2} \right) \delta n_p(x, f) = -\frac{I_0}{2D_p} \frac{1-\gamma_R}{h\nu} \beta e^{-\beta x}, \quad (11)$$

На основу ове једначине се може израчунати динамичка компонента $\delta n_p(x, f)$ која говори о просторној расподели мањинских носилаца дуж x -осе (дуж које се простиру носиоци) која зависи од модулационе фреквенце.

Поред тога што се подразумева да нема продора наелектрисања кроз граничне површине узорка: $\delta n_p(0, f) = 0$, и $\delta n_p(l, f) = 0$, гранични услови за решавање дифузионе једначине (11) укључују постојање рекомбинације на предњој осветљеној ($x=0$), и задњој ($x=l$) неосветљеној површини узорка, и дати су следећим изразима:

$$\frac{d}{dx} \delta n_p(x, f) \Big|_{x=0} = \frac{s_1 \delta n_p(0, f)}{D_p} \quad \text{и} \quad \frac{d}{dx} \delta n_p(x, f) \Big|_{x=l} = -\frac{s_2 \delta n_p(l, f)}{D_p}, \quad (12)$$

где су s_1 и s_2 брзине рекомбинација носилаца наелектрисања на предњој и задњој површини узорка, респективно.

Решење дифузионе једначине (11) је дато у облику [2,10-13,47,50,51]:

$$\delta n_p(x, f) = \left[A_{1\omega} e^{\frac{x}{L}} + A_{2\omega} e^{-\frac{x}{L}} \right] - \frac{\beta I_0}{h\nu D_p (\beta^2 - L^{-2})} e^{-\beta x}, \quad (13)$$

где су $A_{1\omega}$ и $A_{2\omega}$ интеграционе константе које се израчунавају из граничних услова (12) и имају облик:

$$A_{1\omega} = \frac{A_\omega}{a} \cdot \left[(v_{D\omega} - s_2)(v_\beta + s_1) e^{\frac{l}{L}} - (v_{D\omega} + s_1)(v_\beta - s_2) e^{-\beta l} \right] \quad (14a)$$

$$A_{2\omega} = \frac{A_\omega}{a} \cdot \left[(v_{D\omega} + s_2)(v_\beta + s_1) e^{\frac{l}{L}} - (v_{D\omega} - s_1)(v_\beta - s_2) e^{-\beta l} \right] \quad (14b)$$

$$A_\omega = \frac{\beta I_0}{\varepsilon D_p (\beta^2 - L^{-2})} \quad (15)$$

$$a = (v_{D\omega} + s_1) \cdot (v_{D\omega} + s_2) e^{\frac{l}{L}} - (v_{D\omega} - s_1) \cdot (v_{D\omega} - s_2) e^{-\beta l}. \quad (16)$$

Овде су $v_{D\omega} = D_p L^{-1}$ и $v_\beta = \beta D_p$, тзв. дифузионе брзине носилаца.

2.3.4. Израчунавање температурних расподела у полупроводнику

Расподела мањинских фотогенерисаних носилаца дуж полупроводника, описана једначином (13), указује на постојање градијента мањинских носилаца који доводи до њиховог транспорта у узорку. На тај начин фотогенерисани носиоци као носиоци топлоте могу да мењају температурну расподелу у узорку за коју можемо претпоставити да се мења, због модулисане побуде, на начин $T(x, t) = T(x)(1 + e^{i\omega t})$. Осветљавањем полупроводника долази до настанка топлотних извора на местима која су осветљена, због фототермалног ефекта. Поред тога, услед рекомбинације фотогенерисаних носилаца, настају додатни топлотни извори што доводи до додатног загревања полупроводника, како у запремини тако и на његовим површинама. Ако топлотни извор који је настао

осветљавањем означимо са H_1 , а топлотни извор који је настао рекомбинацијом означимо са H_2 , онда те изворе можемо дати у облику:

$$H_1 = \frac{h\nu - \varepsilon_g}{h\nu} \frac{I}{2} \beta e^{-\beta x} \quad \text{и} \quad (17)$$

$$H_2 = \varepsilon_g \frac{\delta n_p(x, t)}{\tau_p}. \quad (18)$$

Уз претпоставку да је $I = I_0(1 + e^{i\omega t})$ и $\delta n_p(x, t) = \delta n_p(x)(1 + e^{i\omega t})$, ови топлотни извори су укључени у термодифузиону једначину:

$$\left(\frac{\partial^2}{\partial x^2} - \frac{1}{D_T} \frac{\partial}{\partial t} \right) T(x, t) = - \frac{H_1 + H_2}{k}, \quad (19)$$

где је D_T термална дифузивност и k термална проводност узорка. Раздвајањем статичког $H(x)$ и динамичког дела $H(x, t)$ у изразима H_1 и H_2 (17) и (18), може се написати:

$$H_1 = H_1(x) + H_1(x, t) = \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{-\beta x} + \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{i\omega t - \beta x}, \quad (20)$$

$$H_2 = H_2(x) + H_2(x, t) = \frac{\varepsilon_g}{\tau_p} \delta n_p(x) + \frac{\varepsilon_g}{\tau_p} \delta n_p(x) e^{i\omega t}. \quad (21)$$

На основу једначина (20) и (21), када се замене у (19), добија се статичка термодифузиона једначина облика (22) и динамичка термодифузиона једначина облика (23):

$$\frac{d^2}{dx^2} T(x) = - \frac{1}{k} \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{-\beta x} - \frac{\varepsilon_g}{k\tau_p} \delta n_p(x), \quad (22)$$

$$\left(\frac{\partial^2}{\partial x^2} - \frac{1}{D_T} \frac{\partial}{\partial t} \right) T(x) e^{i\omega t} = - \frac{1}{k} \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{i\omega t - \beta x} - \frac{\varepsilon_g}{k\tau_p} \delta n_p(x) e^{i\omega t} \quad (23)$$

За наша израчунавања од интереса нам је само једначина (23) јер она утиче на стварање фотоакустичких таласа. Fourie-овом трансформацијом добијамо:

$$\left(\frac{d^2}{dx^2} - \frac{i\omega}{D_T}\right)T(x, \omega) = -\frac{1}{k} \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{-\beta x} - \frac{\varepsilon_g}{k\tau_p} \delta n_p(x, \omega), \quad (24)$$

која се може написати и у облику:

$$\left(\frac{d^2}{dx^2} - \sigma_s^2\right)T(x, f) = -\frac{1}{k} \frac{h\nu - \varepsilon_g}{h\nu} \frac{I_0}{2} \beta e^{-\beta x} - \frac{\varepsilon_g}{k\tau_p} \delta n_p(x, f), \quad (25)$$

где је $\sigma_s = (i+1)\mu^{-1}$ комплексни термални дифузиони коефициент узорка, $\mu = \sqrt{D_T(\pi f)^{-1}}$ је термална дифузиона дужина, $D_T = k(\rho c_p)^{-1}$ је термална дифузивност узорка, k је коефициент термалне проводности, ρ је густина, и c_p је специфична топлота. Користећи одговарајуће почетне и граничне услове, добија се решење ове једначине. Гранични услови на предњој $x=0$, и задњој површини $x=l$ обезбеђују континуитет температуре и топлотног флукса:

$$T_{\text{ваздух}}(0) = T(0), \quad T(l) = T_{\text{ваздух}}(l), \quad (26)$$

$$-k \frac{dT(x)}{dx} \Big|_{x=0} = s_1 \delta n_p(0) \varepsilon_g, \quad (27)$$

и

$$-k \frac{dT(x)}{dx} \Big|_{x=l} = -s_2 \delta n_p(l) \varepsilon_g, \quad (28)$$

где су $s_1 \delta n_p(0) \varepsilon_g$ и $s_2 \delta n_p(l) \varepsilon_g$ површински топлотни извори који постоје због површинске рекомбинације на предњој и задњој површини узорка.

Решење једначине (25) даје динамичку температурну расподелу $T(x, f)$ која се може дати као збир три компоненте:

$$T(x, f) = T_{\text{therm}}(x, f) + T_{\text{br}}(x, f) + T_{\text{sr}}(x, f). \quad (29)$$

где су $T_{\text{therm}}(x, f)$ термализациона компонента (thermalization), $T_{\text{br}}(x, f)$ компонента расподела температуре услед запреминске рекомбинације (bulk recombination temperature distribution) и $T_{\text{sr}}(x, f)$ компонента расподеле температуре услед површинске рекомбинације (surface recombination temperature distribution) [2,10,13,16,47,51].

Једначине за температурну расподелу (динамичке једначине):

$$T_{\text{therm}}(x, f) = \frac{I_0}{k} \frac{\varepsilon - \varepsilon_g}{\varepsilon} \frac{\beta}{\beta^2 - \sigma_i^2} \left[b \frac{e^{\sigma_i(x-l)} + e^{-\sigma_i(x-l)} - e^{-\beta l} (e^{\sigma_i x} + e^{-\sigma_i x})}{e^{\sigma_i l} - e^{-\sigma_i l}} - e^{-\beta x} \right], \quad (30)$$

$$T_{\text{br}}(x, f) = \frac{\varepsilon_g B_1}{\tau k \sigma_i^2} \left\{ \frac{B_2 e^{\sigma_i x} + B_3 e^{-\sigma_i x}}{e^{\sigma_i l} - e^{-\sigma_i l}} - \frac{1}{c^2 - 1} \left[\frac{\delta n_p(x, f)}{B_1} + \frac{b^2 - c^2}{b^2 - 1} e^{-\beta x} \right] \right\}, \quad (31)$$

$$T_{\text{sr}}(x, f) = \frac{2\varepsilon_g}{k\sigma_i} \frac{s_1 \delta n_p(0, f) \cosh[\sigma_i(x-l)] + s_2 \delta n_p(l, f) \cosh(\sigma_i x)}{e^{\sigma_i l} - e^{-\sigma_i l}}, \quad (32)$$

где су константе:

$$b = \frac{\beta}{\sigma_i}, \quad c = \frac{1}{L\sigma_i}, \quad B_1 = -A, \quad B_2 = B_4 e^{-\sigma_i l} + B_5, \quad B_3 = B_4 e^{\sigma_i l} + B_5,$$

и

$$B_4 = -c \frac{\frac{1}{B_1} [\delta n_p(l) - \delta n_p(0) \cosh(l/L)] - \cosh(l/L) + e^{-\beta l}}{\sinh(l/L) \cdot (c^2 - 1)} - \frac{b}{b^2 - 1},$$

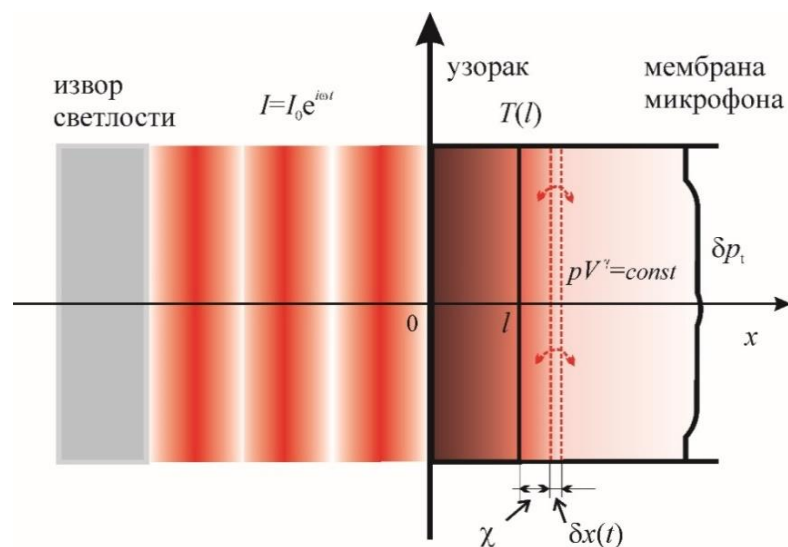
$$B_5 = c \frac{\frac{1}{B_1} [\delta n_p(l) \cosh(l/L) - \delta n_p(0)] - 1 + e^{-\beta l} \cosh(l/L)}{\sinh(l/L) \cdot (c^2 - 1)} + \frac{b e^{-\beta l}}{b^2 - 1}.$$

Из ових једначина се јасно види да на температурне расподеле $T_{\text{br}}(x, f)$ и $T_{\text{sr}}(x, f)$ и укупну вредност $T(x, f)$ битно утиче расподела вишка носилаца $\delta n_p(x, f)$.

2.3.5. Термодифузиони сигнал

На основу разматрања топлотног клипа, поглавље 2.3.1., и извођења температурских расподела у поглављу 2.3.4. приказаћемо поступак добијања облика термодифузионе компоненте сигнала узорка.

Осветљавањем једне стране узорка модулисано светлошћу долази до апсорпције светлости како на површини узорка, тако и у његовој запремини, дубине β^{-1} (апсорпциона дубина). Апсорпцију прати нерадијативна релаксација побуђених молекула супстанце, која доводи до периодичних промена температуре узорка.



Слика 8. Померај топлотног клипа дебљине $2\pi\mu_g$ за $\delta x(t)$ услед чега настаје промена притиска $\delta p(t)$ у ваздуху.

Периодичне промене температуре узорка претставља и периодичну промену температуре ваздуха који га окружује. На основу граничних услова које смо успоставили у (27) сматра се да је температура слоја ваздуха T_g тик уз узорак иста као и температура неосветљене површине $T(l)$ тј. $T_g = T(l)$ (слика 8), и да се промена температуре ваздуха дешава у ваздушном слоју дебљине $\chi = 2\pi\mu_g$ где је μ_g термална дифузиона дужина у ваздуху [7-9].

Тако танак слој ваздуха се периодично загрева, шири и скупља, и представља термални клип који адијабатски сабија и шири остатак ваздуха у ћелији, што доводи до промена притиска $\delta p(t)$ у ваздушној колони између узорка и мембране микрофона и доводи до формирања акустичког таласа:

$$\delta p(t) = \frac{\gamma P_0}{V_0} \delta V = \frac{\gamma P_0}{l_c} \delta x(t), \quad (33)$$

где је γ адијабатска константа или однос специфичних топлота за гас $\gamma = C_p C_v^{-1}$, P_0 притисак и T_0 температура околног ваздуха у коме се плочица налази. Дебљина l_c представља дужину ваздушне колоне тј. пут који пређе звук од узорка до микрофона [3,39-45]. Термална дифузиона дужина у ваздуху је $\mu_g = \sqrt{D_g(\pi f)^{-1}}$, где је D_g коефицијент термалне дифузије ваздуха. Ширење ваздушног слоја за $\delta x(t)$ дуж правца простирања звука (слика 8) описано је са:

$$\delta x(t) = 2\pi\mu_g \frac{\langle T_g(t) \rangle}{T_0}. \quad (34)$$

Овде је $\langle T_g(t) \rangle$ средња промена температуре ваздушног слоја дебљине $2\pi\mu_g$ дефинисана као:

$$\langle T_g(t) \rangle = \frac{1}{2\pi\mu_g} \int_l^{2\pi\mu_g+l} T_g(x,t) dx \approx \frac{1}{2\sqrt{2\pi}} T_g(l,t) e^{-i\frac{\pi}{4}}, \text{ када је } e^{-2\pi} \ll 1. \quad (35)$$

То значи да је, уз услов $T_g(l,t) = T(l)e^{i\omega t}$, промена дебљине ваздушног слоја дата са:

$$\delta x(t) = \frac{\mu_g}{\sqrt{2T_0}} T(l) e^{i\left(\omega t - \frac{\pi}{4}\right)}. \quad (36)$$

Са променом дебљине слоја $\delta x(t)$ (34) долази до промене притиска $\delta p(t)$ (33) ваздуха у остатку ћелије до микрофона, што микрофон бележи као термодифузиони сигнал $\delta p_{\text{TD}}(t) = \delta p(t)$ [31,33]:

$$\delta p_{\text{TD}}(t) = \frac{\gamma P_0}{l_c} \frac{\mu_g}{\sqrt{2T_0}} T(l) e^{i\left(\omega t - \frac{\pi}{4}\right)}. \quad (37)$$

2.3.6. Термоеластични сигнал

На основу анализе модела механичког клипа дате у поглављу 2.3.2., овде ћемо извести израз за термоеластичну компоненту фотоакустичког сигнала [2,4,35-37,43,45]. Ако се узме у обзир да се посматра узорак у облику плочице који има цилиндричну геометрију, разматрања ефекта њеног савијања и ширења најпогодније је извршити у цилиндричним координатама (r, θ, z) .

Периодично савијање и исправљање плочице зависи од динамичке компоненте температурне расподеле (29) која се добија решавањем квазистационарне топлотне дифузионе једначине (25). Узрок настанка термоеластичног сигнала је последица појаве помераја U_r и U_z који настаје услед температурне разлике на осветљеној и неосветљеној страни узорка (слика 9). Укупни померај $U_z(r, z)$ представља збир помераја у правцу z -осе и то: $U_{z1}(r, z)$, који настаје услед савијања узорка и помераја $U_{z2}(r, z)$ који настаје услед ширења узорка [31,33]:

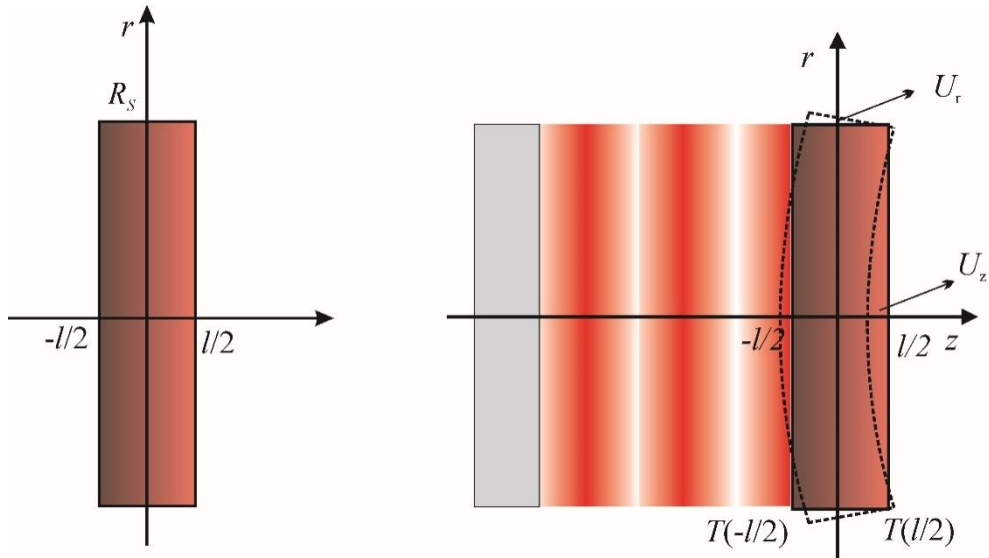
$$U_z(r, z) = U_{z1}(r, z) + U_{z2}(r, z) \quad (38)$$

Генерализан Нооке-ов закон (Generalized Hooke's law) за линеарне, еластичне и хомогене средине даје везу између релативне деформације, напона и температурне расподеле. На основу тих веза могу се добити веза између помераја U_r и U_z (слика 9). Прва веза је једноставна и има облик [31,33]:

$$\frac{\partial U_z}{\partial r} = -\frac{\partial U_r}{\partial z} \quad (39)$$

Друга веза је компликованија. Ако Поасонов однос (Poisson's ratio) означимо са ν , коефицијент линеарног ширења са α_T , релативну деформацију смицања са γ_s а просторну расподелу температуре са $T(z)$, друга веза између помераја U_r и U_z дуж оса r и z има облик [31,33]:

$$\frac{\partial U_z}{\partial z} = \frac{1+\nu}{1-\nu} \alpha_T T(z) - \frac{\nu}{1-\nu} \left(\frac{\partial U_r}{\partial r} + \frac{U_r}{r} \right) \quad (40)$$



Слика 9. Савијање узорка услед загревања за U_r у r правцу, и U_z у правцу z -осе.

На основу једначине (40) добија општи израз за вредност помераја U_r [31,33]:

$$U_r(r, z) = \alpha_T r \cdot \left(\frac{12M_T}{l^3} + \frac{N_T}{l} \right), \quad (41)$$

где M_T је момент савијања плочице, настао услед промене температуре дуж z -осе узорка, а N_T је средња температура у узорку [31,33]:

$$M_T = \int_{-l/2}^{l/2} zT(z)dz \quad \text{и} \quad N_T = \int_{-l/2}^{l/2} T(z)dz. \quad (42)$$

Заменом једначине помераја (41) у везу између помераја U_r и U_z дуж z -осе (40) добија се једначина компоненте помераја U_{z1} који се јавља услед савијања узорка [31,33]:

$$U_{z1}(r, z) = \frac{6\alpha_T}{l^3} M_T (R_s^2 + r^2). \quad (43)$$

Заменом $U_r(r, z)$ (39) у једначину везе (40) између помераја U_r и U_z дуж r -осе, добијамо једначину компоненте помераја U_z дуж z -осе који је одређен ширењем узорка [31,33]:

$$U_{z2}(r, z) = \frac{1+\nu}{1-\nu} \alpha_T \int_{-l/2}^z T(z) dz - \frac{3\nu\alpha_T}{1-\nu} M_T(4z^2 + l^2) - \frac{2\nu\alpha_T}{(1-\nu)l} N_T\left(z + \frac{l}{2}\right). \quad (44)$$

Савијање (43) је у већини случајева много интензивније од ширења (44) [31,33]:

$$U_{z1}(r, z) \gg U_{z2}(r, z). \quad (45)$$

Због једначине (45) једначина (38) се своди на $U_z(r, z) = U_{z1}(r, z)$, тј. [31,33]:

$$U_z(r, z) = \frac{6\alpha_T}{l^3} M_T(R_s^2 + r^2). \quad (46)$$

Компонента фотоакустичног сигнала $\delta p_{TE}(f)$ која је одређена померајем $U_z(r, z)$ услед неједнаког ширења рачуна се помоћу [31,33]:

$$\delta p_{TE}(f) = \frac{p_0 \gamma}{V_0} \int_0^{R_s} 2\pi r \cdot U_z(r, z) dr = \alpha_T \frac{3\pi p_0 \gamma}{V_0} \frac{R_s^4}{l^3} \int_{-l/2}^{l/2} z T(z) dz. \quad (47)$$

У последњој једначини V_0 је запремина тела микрофона $V_0 = \pi R_0^2 l_c$, а R_s је полупречник узорка.

2.3.7. Плазмаеластични сигнал

Анализи фотоакустичког ефекта у претходним поглављима, поред термодифузије и термоеластике за чврстог тела, треба додати и разматрање и утицај фотогенерисаних носилаца као носилаце наелектрисања. Фотогенерисани носиоци се у полупроводнику крећу и утичу на ефекте савијања јер интерагују са чворовима кристалне решетке. Неравнотежна концентрација фотогенерисаних носилаца изазива настанак механичког стреса чији интензитет зависи од концентрације носилаца која је различита на осветљеној и неосветљеној страни. Због тога долази до савијања узорка. Уколико је осветљавање модулисано и савијање је периодично, које доводи до формирања плазмаеластичне компоненте $\delta p_{PE}(f)$ фотоакустичког таласа, дефинисане са [12,13,54-60]:

$$\delta p_{\text{PE}}(f) = d_n \frac{p_0 \gamma}{V_0} \frac{3\pi R_s^4}{l^3} M_n = d_n \frac{p_0 \gamma}{V_0} \frac{3\pi R_s^4}{l^3} \int_{-l/2}^{l/2} z \delta n_p(z) dz. \quad (48)$$

где је M_n момент носилаца. Облик једначине за $\delta p_{\text{PE}}(f)$ је исти као и за $\delta p_{\text{TE}}(f)$, са тим што је уместо температурне расподеле $T(z)$ искоришћена расподела концентрације носилаца $\delta n_p(z)$, а уместо коефициента термалног ширења α_T користи се коефициент електронске деформације d_n . Овим се показује да се у фотоакустици може директно измерити утицај фотогенерисаних носилаца као носилаца наелектрисања.

2.3.8. Укупан фотоакустички одзив полупроводника

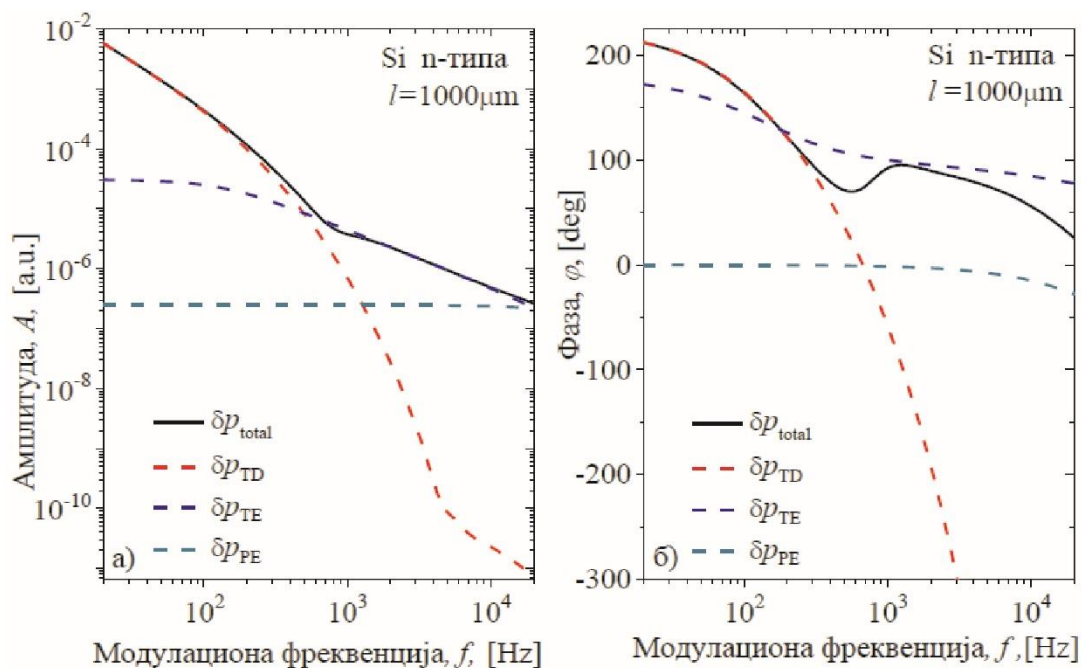
Расподеле температурне дуж полупроводника и температура предње изадње стране узорка су битни за одређивање компоненти ТД и ТЕ фотоакустичког одзива. Укупни ФА сигнал (2) као сума ТД компоненте (37), ТЕ компоненте (47) и ПЕ компоненте (48), се може записати у облику:

$$\delta p_{\text{total}}(f) = \frac{\mu_s \gamma}{\sqrt{2}} \frac{p_0}{T_0 l_c} T(l) e^{i\left(\omega t - \frac{\pi}{4}\right)} + \alpha_T \frac{3\pi \gamma}{l^3} \frac{p_0 R_s^4}{V_0} \int_{-l/2}^{l/2} z T_s(z) dz + d_n \frac{3\pi \gamma}{l^3} \frac{p_0 R_s^4}{V_0} \int_{-l/2}^{l/2} z \delta n_p(z) dz. \quad (49)$$

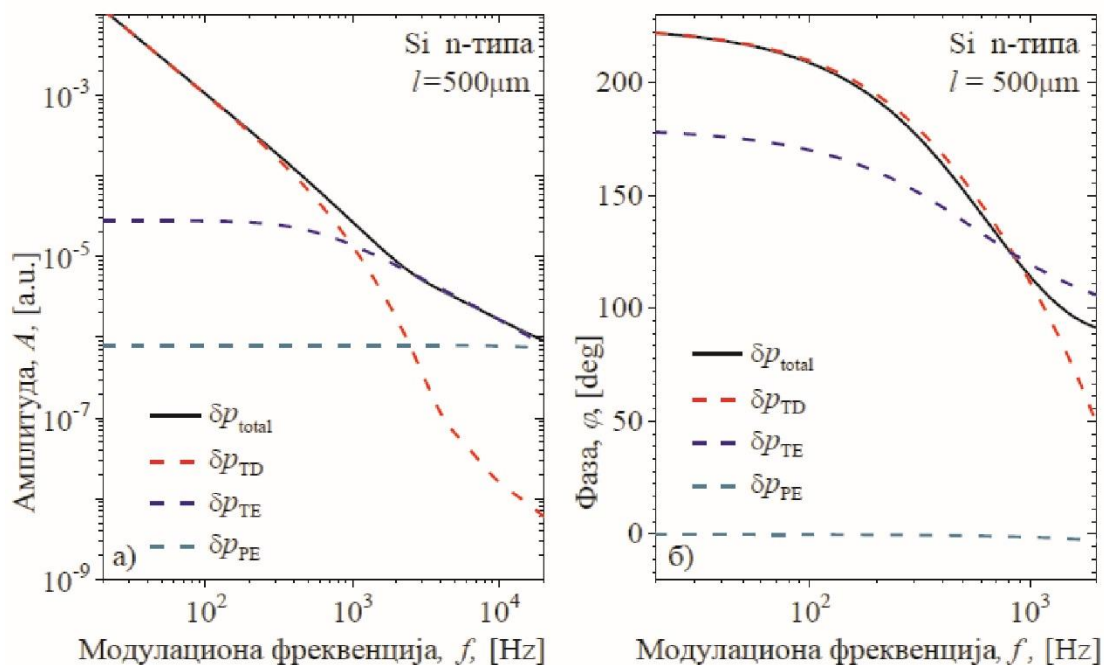
Помоћу једначине (49) [2,13,42,47,51] можемо уочити дирекне зависности укупног фотоакустичког сигнала и то од: концентрације фотогенерисаних носилаца предње и задње стране узорка, од температурне расподеле осветљене и неосветљене стране узорка, и линеарну зависност од коефициента линеарног ширења и електронске деформације. Поред тога показује се зависност од геометријских параметра узорка дебљине као l^{-3} , и полупречника узорка R_s . Све до сада уочене зависности указују на то да су амплитуде и фазе $\delta p_{\text{total}}(f)$ изузетно осетљиве на промене поменутих параметара, што се може лако уочити променом њихових облика зависности у фреквентном домену.

На сликама 10. 11. и 12. се показује како укупни фотоакустични сигнал мења свој облик са смањењем дебљине. Карактеристични седласт облик укупног фотоакустичког сигнала $\delta p_{\text{total}}(f)$ изразит је за дебљину од 1000 μm и у амплитуди $A(f)$ и у фази $\varphi(f)$.

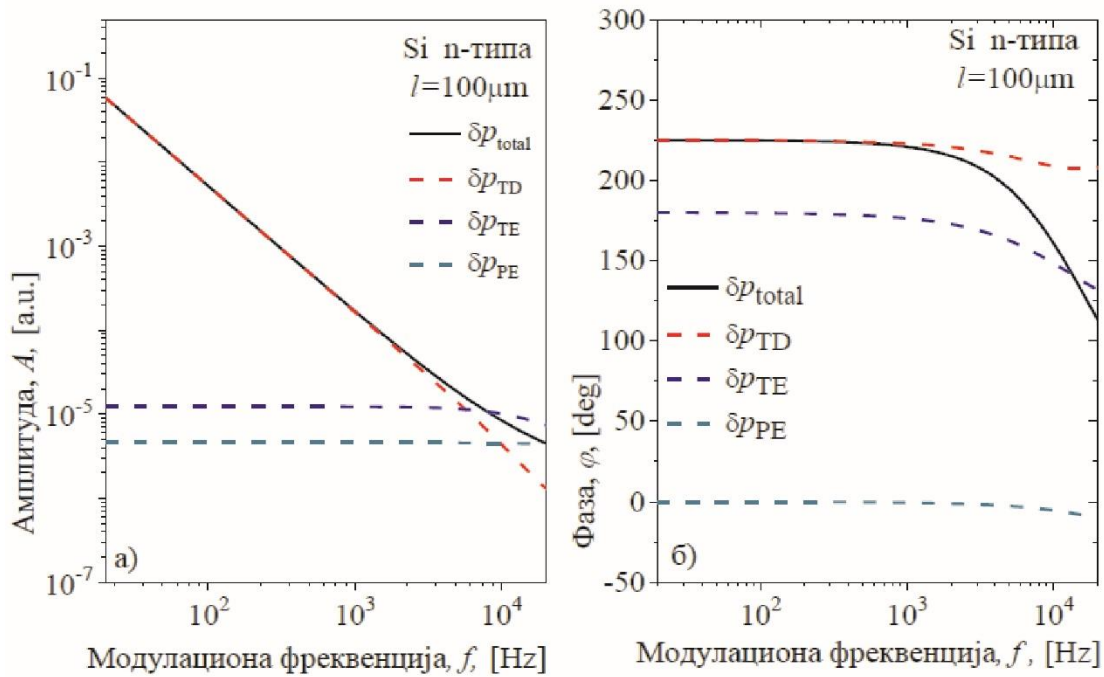
Смањењем дебљине на $500\mu\text{m}$ и $100\mu\text{m}$ седласт облик се смањује и, на најтањем узорку, потпуно губи.



Слика 10. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{\text{total}}(f)$, са компонентама термодифузионом $\delta p_{\text{TD}}(f)$, термоеластичном $\delta p_{\text{TE}}(f)$ и плазмаеластичном $\delta p_{\text{PE}}(f)$ Si n-типа за дебљину $1000\mu\text{m}$.



Слика 11. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{\text{total}}(f)$, са компонентама термодифузионом $\delta p_{\text{TD}}(f)$, термоеластичном $\delta p_{\text{TE}}(f)$ и плазмаеластичном $\delta p_{\text{PE}}(f)$ Si n-типа за дебљину $500\mu\text{m}$.



Слика 12. а) Амплитуда и б) фаза укупног фотоакустичког сигнала $\delta p_{\text{total}}(f)$, са компонентама термодифузионом $\delta p_{\text{TD}}(f)$, термоеластичном $\delta p_{\text{TE}}(f)$ и плазмаеластичном $\delta p_{\text{PE}}(f)$ Si n-типа за дебљину $100 \mu\text{m}$.

На основу фотоакустичких сигнала $\delta p_{\text{total}}(f)$ (49) са одговарајућим компонентама $\delta p_{\text{TD}}(f)$ (37), $\delta p_{\text{TE}}(f)$ (47) и $\delta p_{\text{PE}}(f)$ (48), датих на сликама 10. 11. и 12. омогућена је даља анализа, која се састоји у томе да се пронађу области доминације поменутих ефеката у задатим фреквентним доменима. Јасно је, са слика, да је термодифузиони ефекат доминантан у нискофреквентном делу, тј да у тој области компонента термалне дифузије $\delta p_{\text{TD}}(f)$ доминира у укупном фотоакустичком сигналу $\delta p_{\text{total}}(f)$. Са смањењем дебљине, слике 11 и 12, постаје очигледно да термодифузиона компонента $\delta p_{\text{TD}}(f)$ постаје доминантнија у ширем фреквентном опсегу. Термоеластични ефекат је доминантан код дебљих узорака у високофреквентном делу, тј кажемо да у тој области доминира $\delta p_{\text{TE}}(f)$ компонента у укупном сигналу $\delta p_{\text{total}}(f)$. Са смањењем дебљине, доминација компоненте $\delta p_{\text{TE}}(f)$ се смањује и потпуно ишчезава код најтањих узорака.

Плазмаеластични ефекти су мали, тј удео компоненте $\delta p_{\text{PE}}(f)$ у укупном сигналу $\delta p_{\text{total}}(f)$ је најчешће занемарљив.

На сликама 10, 11 и 12 се уочава да је облик укупног сигнала $\delta p_{\text{total}}(f)$ код полупроводника у највећој мери одређен односом компоненти $\delta p_{\text{TD}}(f)$ и $\delta p_{\text{TE}}(f)$.

2.4. Корекција фотоакустичког сигнала

У било којем фотоакустичком експерименту, главни проблем мерења може бити изобличење сигнала због шума и утицаја мерних инструмената. Развијене су методе за корекције амплитуде и фазе фотоакустичких сигнала у зависности од фреквенције у присуству кохерентног и некохерентног шума, као и изобличења због коришћених инструмената [30-36]. Да бисмо поједноставили нашу анализу, овде ћемо дати приказ корекције експерименталног и добијање „правог“ фотоакустичког сигнала сматрајући све измерене шумове занемарљиво малим у односу на измерени сигнал.

Добро је позната чињеница да сваки резултат мерења у фотоакустици $Y(f)$ може да се изрази као збир компоненти мереног сигнала $S(f)$ и шума $N(f)$ [54-57]:

$$Y(f) = S(f) + N(f). \quad (50)$$

Овде је $N(f)$ дефинисано једначином:

$$N(f) = N_{\text{FN}}(f) + N_{\text{CSD}}(f), \quad (51)$$

где је $N_{\text{FN}}(f)$ микрофонски тзв. фликер шум (flicker noise, FN), а $N_{\text{CSD}}(f)$ је тзв. кохерентна сметња (Coherent Signal Deviation, CSD). Уколико се успоставе такви експериментални услови при којима су вредности $N_{\text{FN}}(f)$ и $N_{\text{CSD}}(f)$ много мање од мереног сигнала $S(f)$, мерни сигнал се може дефинисати са:

$$S(f) = \delta p_{\text{total}}(f) H(f), \quad (52)$$

где је $H(f) = H_{\text{total}}^e(f) H_{\text{total}}^a(f)$ преносна функција електро-акустичких реакција мерног система електронског $H_{\text{total}}^e(f)$ и акустичког типа $H_{\text{total}}^a(f)$. Величина $\delta p_{\text{total}}(f)$ представља

фотоакустички сигнал генерисан од стране узорка, тзв "прави" фотоакустички сигнал представљен једначином (49).

Сваки инструмент повезан на наш детекциони систем има своје RC карактеристике и може да ослаби сигнал узорка у нискофреквентној области модулационих фреквенција тј. понаша се као RC филтер пропусник високих учестаности. Ефекти филтра пропусника високих учестаности у нашем фотоакустичком систему систему описују се преносном функцијом $H_{total}^e(f)$ која одговара каскадној вези више филтара. Показало се да у нашим мерењима највећи утицај на сигнал имају микрофон и звучна картица рачунара коју користимо као замену за lock-in појачивач. Због тога $H_{total}^e(f)$ представљамо једноставно као каскадну везу два филтра пропусника високих учестаности у облику [30-36]:

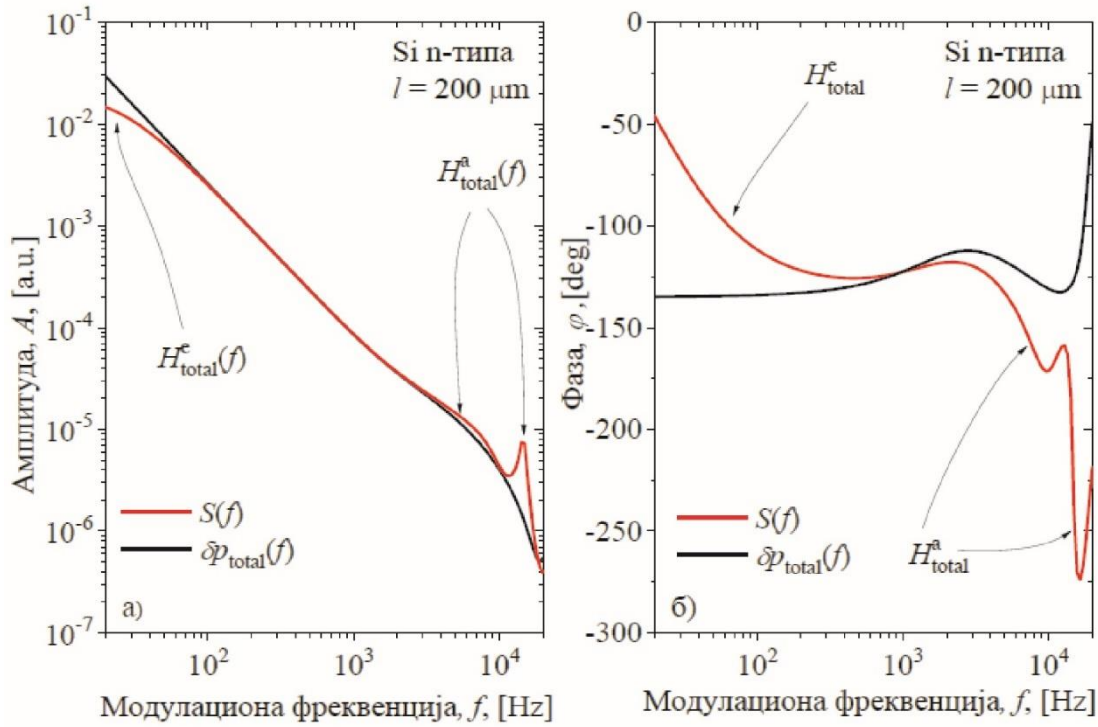
$$H_{total}^e(f) = H_1^e(i\omega) \cdot H_2^e(i\omega) = -\frac{\omega \tau_{c1}}{(1 + i\omega \cdot \tau_{c1})} \cdot \frac{\omega \tau_{c2}}{(1 + i\omega \cdot \tau_{c2})}, \quad (53)$$

где је $\omega = 2\pi f$, $H_1^e(i\omega)$ и $H_2^e(i\omega)$ су одговарајуће преносне функције микрофона са припадајућом електроником и звучне картице, а $\tau_{c1} = (2\pi f_{c1})^{-1}$ и $\tau_{c2} = (2\pi f_{c2})^{-1}$ су одговарајуће временске константе које се одређују на основу познатих карактеристика из постојећих упутстава за употребу или фитовањем експерименталних података.

На основу нашег експерименталног искуства, узимајући у обзир све наведене геометријске ефекте и ефекте везане за материјал мембране, микрофона кроз процес акустичког филтрирања може се описати реакција микрофона као акустичког филтра пропусника ниских учестаности. Овај филтер се описује сложеном преносном функцијом другог реда $H_{total}^a(f)$ која се у нашем случају описује комбинацијом два филтра, јер се њен утицај испољава појавом два карактеристична пика у високо фреквентном делу, (слика 13):

$$H_{total}^a(f) = \frac{\omega_{c3}^2}{\omega_{c3}^2 + \delta_{c3}i\omega - \omega^2} + \frac{\omega_{c4}^2}{\omega_{c4}^2 + \delta_{c4}i\omega - \omega^2}, \quad (54)$$

где је δ_j фактор пригушења ($j = c3, c4$), ω_{c3} и ω_{c4} су карактеристичне фреквенције пикова које зависе од геометрије микрофона. У нашем случају фреквенција наглог пада сигнала (тзв. cut-off frequency) је ω_{c4} фреквенција.



Слика 13. Симулиране амплитуде а) A и фазе б) φ укупног фотоакустичког $\delta p_{\text{total}}(f)$ (црна линија) и искривљеног експерименталног $S(f)$ сигнала (црвена линија) у функцији фреквенције модулације f . Електронски $H_{\text{total}}^e(f)$ и акустички $H_{\text{total}}^a(f)$ одзив експерименталних уређаја назначен је стрелицама.

Главни циљ сваког експеримента је да се добије $\delta p_{\text{total}}(f)$ (слика 13) и из њега извуку термички и механички параметри узорка. То се може постићи применом процедуре корекције сигнала дате у следећим корацима: 1) пронаћи експерименталне услове који ће омогућити да $N_{\text{FN}}(f)$ и $N_{\text{CSD}}(f)$ буду занемарљиво мали; 2) фитовати $S(f)$ (52) и тако добити електро-акустичне карактеристике $H_{\text{total}}^e(f)$ и $H_{\text{total}}^a(f)$ помоћу једначина (53) и (54); 3) кориговати $S(f)$ са $H(f)$ и тако добити "прави" фотоакустички сигнал $\delta p_{\text{total}}(f)$.

Литература (Поглавље 2)

- [1] A. Mandelis (ed.), Photoacoustic and Thermal Wave Phenomena in Semiconductors (Elsevier, New York, 1987) [ISBN-10: 0444012265](#)
- [2] A. Mandelis, P. Hess (eds.), Semiconductors and Electronic Materials, Vol. IV in the Series: Progress in Photothermal and Photoacoustic Science and Technology (SPIE Press, Bellingham, 2000) [ISBN: 9780819435064](#)
- [3] A. Rosencwaig and A. Gersho, Theory of photoacoustic effect with solids, *J. Appl. Phys* **47**, 64 (1976) <https://doi.org/10.1063/1.322296>
- [4] F. A. Mc Donald and G. C. Wetsel, Generalised theory of the photoacoustic effect, *J. Appl. Phys.* 49, 2313 (1978) <https://doi.org/10.1063/1.325116>
- [5] A. G. Bell, On the production and reproduction of sound by light, *Am. J. Sci.* 20(118), 305-324 (1880) <http://dx.doi.org/10.2475/ajs.s3-20.118.305>
- [6] Lord Rayleigh, The Theory of Sound, *Macmillan and Co.*, (1877).
- [7] A. Rosencwaig, Photoacoustic spectroscopy of solids, *Opt. Commun.* 7(4), 305-308 OPCOB80030-4018 (1973) [http://dx.doi.org/10.1016/0030-4018\(73\)90039-4](http://dx.doi.org/10.1016/0030-4018(73)90039-4)
- [8] A. Rosencwaig and A. Gersho, Photoacoustic effect with solids: A theoretical treatment, *Science*, 19 (4214): 556-557, ISSN, 368075 (1975) [DOI: 10.1126/science.190.4214.556](https://doi.org/10.1126/science.190.4214.556)
- [9] A. Rosencwaig, Photoacoustics and Photoacoustic Spectroscopy, John Wiley & Sons Inc, New York (1980) <https://doi.org/10.1121/1.388608>
- [10] D. D. Markushev, J. Ordonez-Miranda, M. D. Rabasovic, S. Galovic, D. M. Todorovic, S. E. Bialkowski, Effect of the absorption coefficient of aluminium plates on their thermoelastic bending in photoacoustic experiments *J. Appl. Phys.* 117, 245309 (2015) <https://doi.org/10.1063/1.4922718>
- [11] M. N. Popovic, M. V. Nestic, M. Zivanov, D. D. Markushev, S. P. Galovic, Photoacoustic response of a transmission photoacoustic configuration for two-layer samples with thermal memory. *Opt Quant Electron* 50 (9):330 (2018) [DOI: 10.1007/s11082-018-1586-x](https://doi.org/10.1007/s11082-018-1586-x)
- [12] D. M. Todorovic, P. M. Nikolic, M. D. Dramicanin, D. G. Vasiljevic, and Z. D. Ristovski, Photoacoustic frequency heat transmission technique: Thermal and carrier transport parameters measurements in silicon, *J. Appl. Phys.* 78, 5750 (1995) <https://doi.org/10.1063/1.359637>
- [13] M. D. Dramićanin, P. M. Nikolić, Z. D. Ristovski, D. G. Vasiljević, and D. M. Todorović, Photoacoustic investigation of transport in semiconductors: Theoretical and experimental study of a Ge single crystal, *Physical Review B*, **51**, 14226 (1995). <https://doi.org/10.1103/PhysRevB.51.14226>
- [14] M. Nestic, S. Galovic, Z. Soskic, M. Popovic, D. M. Todorovic Photothermal Thermoelastic Bending for Media with Thermal Memory. *Int J Thermophys*, 33, 2203-2209 (2012) [DOI: 10.1007/s10765-012-1237-6](https://doi.org/10.1007/s10765-012-1237-6)
- [15] V. Miletic, K. Djordjevic, D. Markushev, M. Popović, S. Galović, D. Miličević, M. Nešić, Priprema PLLA uzoraka i snimanje njihovog fotoakustičkog odziva. Tumačenje kroz model dvoslojnih struktura, 19th International Symposium INFOTEH-JAHORINA (2020)
- [16] D. M. Todorović, M. D. Rabasović, D. D. Markushev, M. Sarajlic, Photoacoustic elastic bending in thin film-substrate system: Experimental determination of the thin film parameters. *J Appl Phys* 116 053506 (2014) <https://doi.org/10.1063/1.4890346>

- [17] J. J. Alvarado-Gil, O. Zelaya-Angel, F. Sanchez-Sinencio, H. Vargas, J. L. Lucio Photoacoustic thermal characterization of a semiconductor (CdTe)-glass two layer system. *Vacuum* **46** 883 (1995) [https://doi.org/10.1016/0042-207X\(95\)00063-1](https://doi.org/10.1016/0042-207X(95)00063-1)
- [18] J. J. Alvarado-Gil, O. Zelaya-Angel, H. Vargas, J. L. Lucio, Photoacoustic characterization of the thermal properties of a semiconductor-glass two-layer system. *Phys Rev B* **50** 14627 (1994) <https://doi.org/10.1103/PhysRevB.50.14627>
- [19] S. Bialkowski, *Photothermal Spectroscopy Methods for Chemical Analysis*(New York: John Wiley 1996) ISBN: 978-0-471-57467-5
- [20] M. V. Marquerinit, N. Cellat, A. M. Mansanares, H. Vargas, and L. C. M. Miranda, Open photoacoustic cell spectroscopy, *Meas. Sci. Technol*, **2**,396401 (1991) <https://doi.org/10.1088/0957-0233/2/4/020>
- [21] L. Choi J-Tae, D. W. Boo, J-G Choia, Determination of Doping Density in GaAs Semiconductor by Wavelength-Dependent Photoacoustic Spectroscopy. *Bull Kor Chem Soc*, **35** 3 895 (2014) <http://dx.doi.org/10.5012/bkcs.2014.35.3.895>
- [22] N. Mikoshiba, H. Nakamura and K. Tsubouchi, Investigation of nonradiative processes in semiconductors by photoacoustic spectroscopy zno transducer, in *Ultrasonic Symposium Proceedings, IEEE, New York*, p.580 (1982). DOI: [10.1109/ULTSYM.1982.197894](https://doi.org/10.1109/ULTSYM.1982.197894)
- [23] D. M. Todorovic, P. M. Nikolic, A. I. Bojicic, K. T. Radulovic, Thermoelastic and electronic strain contribution to the frequency transmission photoacoustic effect in semiconductors, *Phys. Rev. B* **55**, 15631–15642 (1997) DOI:<https://doi.org/10.1103/PhysRevB.55.15631>
- [24] P. Almond, P. Patel, *Photothermal Science and Technique* (London: Chapman and Hall 1996) ISBN 978-0-412-57880-9
- [25] M. D. da Silva, I.N. Bandeira, L. C. M. Miranda, Open-cell photoacoustic radiation detector. *J. Phys. E, Sci. Instrum.* **20**, 12 (1987) DOI: [10.1088/0022-3735/20/12/009](https://doi.org/10.1088/0022-3735/20/12/009)
- [26] L. F. Perondi, L. C. M. Miranda, Minimal volume photoacoustic cell measurement of thermal diffusivity: Effect of the thermoelastic sample bending, *J. Appl. Phys.* **62**, 2955 (1987) <https://doi.org/10.1063/1.339380>
- [27] M. D. Rabasović, M. G. Nikolić, M. D. Dramićanin, M. Franko and D. D. Markushev, Low-cost, portable photoacoustic setup for solid state, *Meas. Sci. Technol*, **20**, **9**, (2009) [doi:10.1088/0957-0233/20/9/095902](https://doi.org/10.1088/0957-0233/20/9/095902)
- [28] М. Поповић, Фотоакустички одзив трансмисионе фотоакустичке конфигурације и анализе и анализа резонантних феномена за двослојне узорке са топлотном меморијом, Докторска дисертација, Универзитет у Новом Саду, Факултет техничких наука (2016) <http://nardus.mpn.gov.rs/123456789/6810>
- [29] М. В. Нешић, Развој техника за решавање инверзног фотоакустичког проблема, Докторска дисертација, Универзитет у Београду, Електротехнички факултет (2018) <http://nardus.mpn.gov.rs/123456789/9456>
- [30] J. A. Balderas-Lopez, A. Mandelis, Thermal diffusivity measurements in the photoacoustic open-cell configuration using simple signal normalization techniques. *J. Appl. Phys.* **90**, 2273 (2001) <https://doi.org/10.1063/1.1391224>
- [31] D. D. Markushev, M. D. Rabasovic, D. M. Todorovic, S. Galovic, S. E. Bialkowski, Photoacoustic signal and noise analysis for Si thin plate: Signal correction in frequency domain, *Rev. Sci. Instrum.* **86**, 035110 (2015), [doi: 10.1063/1.4914894](https://doi.org/10.1063/1.4914894)
- [32] M. N. Popovic, M. V. Nestic, S. Ciric-Kostic, M. Zivanov, D. D. Markushev, M. D. Rabasovic, S. P. Galovic, Helmholtz Resonances in Photoacoustic Experiment with Laser-Sintered Polyamide Including Thermal Memory of Samples. *IntJThermophys*, **37** (12) 116, 9 (2016) [10.1007/s10765-016-2124-3](https://doi.org/10.1007/s10765-016-2124-3)

- [33] S. M. Aleksić, D. K. Markushev, D. S. Pantić, M. D. Rabasović, D. D. Markushev, D. M. Todorović, Electro-Acoustic influence of the measuring system on the photoacoustic signal amplitude and phase in frequency domain, *FU Phys Chem Tech*, 14, (1), pp. 9 – 20 (2016) [DOI: 10.2298/FUPCT1601009A](https://doi.org/10.2298/FUPCT1601009A)
- [34] M. I. Jordović-Pavlović, M. M. Stanković, M. N. Popović, Ž. M. Čojbašić, S. P. Galović, D. D. Markushev, The application of artificial neural networks in solid-state photoacoustics for the recognition of microphone response effects in the frequency domain. *J Comput Electron* (2020). <https://doi.org/10.1007/s10825-020-01507-4>
- [35] M. I. Jordovic-Pavlovic, A. D. Kupusinac, K. Lj. Djordjevic. et al. Computationally intelligent description of a photoacoustic detector. *Opt Quant Electron* 52, 246 (2020). doi.org/10.1007/s11082-020-02372-y
- [36] M. J. Pavlović, M. Popović, D. Markushev and S. Galović: Deep Learning in Development of Model-Dependent Diagnostic: Recognition of Detector Characteristics in Measured Responses, proceedings of 6th International conference on electrical, electronic, and computing engineering (2019) (IcETRAN), [ISBN 978-86-7466-785-9](https://doi.org/10.1007/978-86-7466-785-9)
- [37] F. McDonald, G. Wetsel, Generalized theory of the photoacoustic effect. *J. Appl. Phys.* 49, 2313 (1978) <https://doi.org/10.1063/1.325116>
- [38] F. A. McDonald and G. C. Wetsel, Theory of Photothermal and Photoacoustic Effects in Condensed Matter (1988) [DOI:10.1016/B978-0-12-477918-1.50010-2](https://doi.org/10.1016/B978-0-12-477918-1.50010-2)
- [39] D. Fournier, A. C. Boccara, A. Skumanich and N. M. Amer, Photothermal investigation of transport in semiconductors: Theory and experiment, *J. App Phys.* 59, 787, (1986) <https://doi.org/10.1063/1.336599>
- [40] V. A. Sablikov and V. B. Sandomirskii, The photoacoustic effect in semiconductors, *Phys. stat. sol. (b)* 120 471 (1983) <https://doi.org/10.1002/pssb.2221200203>
- [41] A. Pinto Neto, H. Vargas, N. F. Leite and L. C. M. Miranda, Photoacoustic investigation of semiconductors: Influence of carrier diffusion and recombination in PbTe and Si. *Phys Rev B Condens Matter.* 40 (6): 3924-3930 (1989) [DOI: 10.1103/physrevb.40.3924](https://doi.org/10.1103/physrevb.40.3924)
- [42] D. M. Todorović and P. M. Nikolić, Semiconductors and Electronic Materials Progress in Photothermal and Photoacoustic Science and Technology Chap. 9 (New York: Optical Engineering Press) (2000) 273–318. ISBN: [9780819435064](https://doi.org/10.1007/9780819435064)
- [43] E. Marin, H. Vargas, P. Diaz and I. Riech, On the Photoacoustic Characterization of Semiconductors: Influence of Carrier Recombination on the Thermodiffusion, Thermoelastic and Electronic Strain Signal Generation Mechanisms *Phys. Status Solidi A-Appl.* 179 387 (2000) [https://doi.org/10.1002/1521-396X\(200006\)179:23.0.CO;2-Y](https://doi.org/10.1002/1521-396X(200006)179:23.0.CO;2-Y)
- [44] K. Lj. Djordjevic, D. D. Markushev, Ž. M. Čojbašić, et al. Photoacoustic Measurements of the Thermal and Elastic Properties of n-Type Silicon Using Neural Networks. *Silicon* (2019) [doi:10.1007/s12633-019-00213-6](https://doi.org/10.1007/s12633-019-00213-6)
- [45] G. Roussel, F. Lepoutre, L. Bertrand, Influence of thermoelastic bending on photoacoustic experiments related to measurements of thermal diffusivity of metals, *J. Appl. Phys.* 54, pp. 2383-2391, (1983) <https://doi.org/10.1063/1.332352>
- [46] Y. G. Gurevich, I. Lashkevych, Sources of Fluxes of Energy, Heat, and Diffusion Heat in a Bipolar Semiconductor: Influence of Nonequilibrium Charge Carriers. *Int J Thermophys* 34 341 (2013) <https://doi.org/10.1007/s10765-013-1416-0>

- [47] D. K. Markushev, D. D. Markushev, S. M. Aleksic, D. S. Pantic, S. P. Galovic, D. M. Todorovic, and J. Ordonez-Miranda, Effects of the photogenerated excess carriers on the thermal and elastic properties of n-type silicon excited with a modulated light source: Theoretical analysis, *J. Appl. Phys.*, 126, 185102 (2019) [doi: 10.1063/1.5100837](https://doi.org/10.1063/1.5100837)
- [48] K. Lj. Djordjevic, D. D. Markushev, Ž. M. Čojbašić, S. P. Galović, Inverse problem solving in semiconductor photoacoustics by neural networks INVERSE PROBL SCI EN, under review.
- [49] K. Lj. Djordjevic, S. P. Galovic, M. I. Jordovic-Pavlovic, et al. Photoacoustic optical semiconductor characterization based on machine learning and reverse-back procedure. *Opt Quant Electron* 52, 247 (2020). <https://doi.org/10.1007/s11082-020-02373-x>
- [50] D. D. Markushev, J. Ordonez-Miranda, M. D. Rabasović, M. Chirtoc, D. M. Todorović, S. E. Bialkowski, D. Korte and M. Franko, Thermal and elastic characterization of glassy carbon thin films by photoacoustic measurements, *Eur. Phys. J. Plus* 132(1):33 (2017) [DOI: 10.1140/epjp/i2017-11307-2](https://doi.org/10.1140/epjp/i2017-11307-2)
- [51] D. K. Markushev, D. D. Markushev, S. Galović, S. Aleksić, D. S. Pantić, D. M. Todorović, The surface recombination velocity and bulk lifetime influences on photogenerated excess carrier density and temperature distributions in n-type silicon excited by a frequency-modulated light source, *FU Elec Energ* **31**(2) 313 – 328 (2018) <https://doi.org/10.2298/FUEE1802313M>
- [52] G. G. De la Cruz and Y. G. Gurevich, Electron and phonon thermal waves in semiconductors: An application to photothermal effects, *J. Appl. Phys.* 80 1726 (1996) <https://doi.org/10.1063/1.362971>
- [53] J. Opsal and A. Rosencwaig, Thermal and plasma wave depth profiling in silicon, *App. Phys. Lett.* **47**, 498 (1985) <https://doi.org/10.1063/1.96105>
- [54] D. M. Todorovic, M. D. Rabasovic, D. D. Markushev, V. Jovic, K. T. Radulovic, Investigation of Micromechanical Structures by Photoacoustic Elastic Bending Method, *Int J Thermophys*, **33**, (2012) 2222–2229. [doi: 10.1007/s10765-012-1242-9](https://doi.org/10.1007/s10765-012-1242-9)
- [55] D. M. Todorović, M. D. Rabasović, D. D. Markushev, V. Jović, K. T. Radulović, M. Sarajlić, Photoacoustic Elastic Bending Method: Characterization of Thin Films on Silicon Membranes, *Int J Thermophys* **36**1016–1028 (2015) <https://doi.org/10.1007/s10765-014-1801-3>
- [56] L. C. Miranda, Theory of photoacoustic effect in semiconductors influence of carrier diffusion and recombination. *Appl Opt* 21 (16) (1982) [doi: 10.1364/AO.21.002923](https://doi.org/10.1364/AO.21.002923)
- [57] A. Pinto Neto, H. Vargas, N. F. Leite and L. C. M. Miranda, Photoacoustic characterization of semiconductors: Transport properties and thermal diffusivity in GaAs and Si, *Phys. Rev.B* 41, 9971 (1990) [DOI:https://doi.org/10.1103/PhysRevB.41.9971](https://doi.org/10.1103/PhysRevB.41.9971)
- [58] P. T. Landsberg, Recombination in Semiconductors (Cambridge University, Cambridge, England 1991). DOI: <https://doi.org/10.1017/CBO9780511470769>
- [59] I. N. Volovichev, G. N. Logvinov, Recombination and lifetimes of charge carriers in semiconductors, *J. App Phys.* 95, 4494 (2004); <https://doi.org/10.1063/1.1669074>
- [60] R. G. Stearns, G. S. Kino, Photoacoustic Techniques for the Measurement of Electronic Properties of Semiconductors, Chap.9 in Photoacoustic and Thermal Wave Phenomena in Semiconductors, A. Mandelis Ed., *Elsivier Sci.Pub.Co.*, North-Holland, N.York, p.201 (1987).

3. НЕУРОНСКЕ МРЕЖЕ ЗА ИНВЕРЗНО РЕШАВАЊЕ ФОТОАКУСТИЧКОГ ПРОБЛЕМА

У претходном поглављу 2. су дати теоријски резултати и дискусија веза између снимљеног акустичког сигнала и физичких својстава полупроводника осветљеног са једне стране. Показано је да постоји изражена нелинеарна вишепараметарска зависност. На основу спроведене анализе, а знајући да неуронске мреже са великим успехом препознају било какву нелинеарну зависност, у овом поглављу образложена је идеја и развијене су неуронске мреже прилагођене инверзном решавању фотоакустичког проблема.

Инверзни проблем, у општем случају, је поступак којим се из добијених резултата мерења, као последице, тежи проналажењу узрока који доводе до мерених сигнала. У науци се све више развијају методе за решавање инверзног проблема због тога што је већина мерења индиректна, односно већина параметара не може директно да се мери, већ само посредно, преко неког детектабилног ефекта.

Идеја примене неуронских мрежа у инверзном решавању фотоакустичког проблема у овом раду састоји се у следећем. Помоћу неуронских мрежа се основни физички параметри испитиваног узорка (последице) одреде прецизно, поуздано и у релативном времену, анализирајући добијене амплитуде и фазе сигнала [61-64]. Параметри добијени предикцијом мреже се враћају у теоријски модел како би се извршила потпуна анализа физичких процеса унутар узорка тј. одредили доминантни ефекти (узроци) у појединим фреквентним доменима и на тај начин омогућило одређивање још неких својстава испитиваног узорка..

3.1. Карактеристике неуронских мрежа

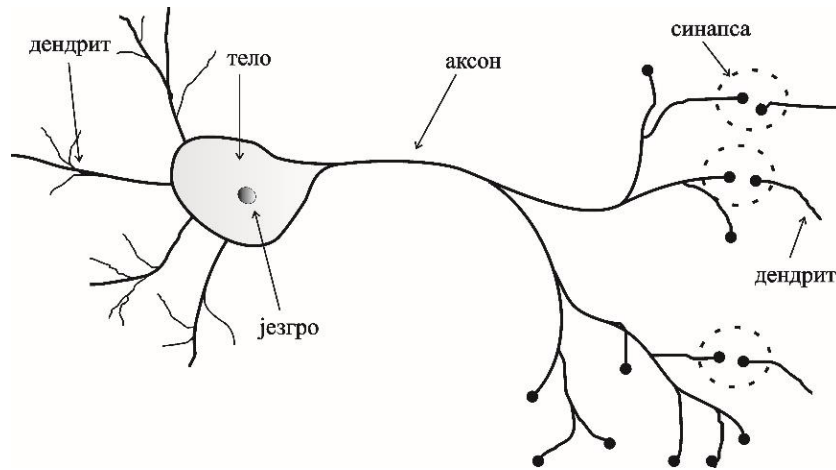
На основу анализе понашања и утврђивањем правилности живих система формиран су модели вештачке интелигенције (Artificial Intelligence) који, у најширем смислу, претстављају способност компјутерских програма или машина да размишљају и уче. Вештачка интелигенција покушава да компјутере учини „паметним“, способним да извршавају задатке за које је потребна људска интелигенција. Тако су се, у оквирима вештачке интелигенције, развиле различите класе проблема које се решавају различитим алгоритмима: од класификације, доношења одлука, препознавање објеката, кластирања,

селекција, распознавање образаца понашања или шаблона, компресија података, детекција аномалија, предикције случајних догађаја, формирање рачунарског вида, визуелизација, и друге [65,66].

Машинско учење (Machine learning) је област вештачке интелигенције која се бави изградњом рачунарских, паметних система који уче из искуства, тј. усвајају знања из података са којима се уче. Тако се добијају системи који имају посебну логику за функционисање. Алгоритми машинског учења могу бити или надгледани (Supervised learning) или ненадгледани (Unsupervised learning). У оквирима надгледаног учења се утврђују правила повезаности између улазних и излазних бројчаних података, при чему имамо познат излаз, тако да се учење заснива на разлици која се јавља између предикције и тачне вредности излаза. Код надгледаног учења постоје две класе проблема: а) регресија (Regression) у којој је вредност излаза континуална тј. нумеричка, и б) класификација (Classification) у којој је вредност излаза дискретна и претставља припадност одговарајућој класи. Када говоримо о ненадгледаном учењу онда се оно огледа у непостојању излазних вредности већ о чистој информацији о повезаности података који немају редослед. У оквирима ненадгледаног учења постоје две класе проблема: а) кластеровање (Clustering) где се праве кластери (групе) са сличним понашањима и б) асоцијације (Association) која тржи корелацију између података у бази података [67,68].

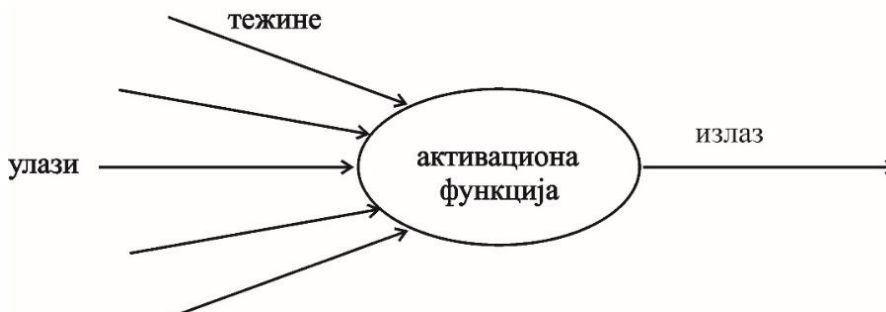
Реплицирањем структуре и функција људског мозга којима се учи, формиране су неуронске мреже (Neural Network или Artificial Neural Network) . Они постају популарани алгоритми машинског учења [69,71]. Постоји велики број различитих врста неуронских мрежа у домену вештачке интелигенције које служе за решавање различитих проблема. Основна структура неуронске мреже подразумева две основне компоненте: чворове и везе између њих. Чворови (неурони) се могу посматрати као структурна, рачунарска и конекциона јединица, који извршавају нелинеарну и параметарску функцију. Ова обрада података може бити врло једноставна (као што је, нпр. сумирање свих података са улаза), или прилично сложена (један чвор може да садржи другу мрежу ...). Везе између чворова одређују проток информација између њих. Оне могу бити једносмерне, када информација тече само у једном смеру, и тада чини мреже са пропагацијом унапред - forward (од једног ка другом чвору), и двосмерне, када информације теку у оба смера, мреже са пропагацијом уназад - backward. Интеракције између чворова, кроз везе, доводе до специфичног колективног понашања мреже, које је потпуно другачије од понашања њених појединачних елемената. Специфичност понашања мреже као колектива је у томе што оно увећава способност мреже у односу на способности њених елемената, чинећи неуронску мрежу

веома моћним алатом за решавање проблема. Зато се неуронске мреже користе за моделирање широког спектра појава у физици, рачунарству, биологији, хемији, математици, социологији, економији, телекомуникацијама и многим другим областима [72-76].



Слика 14. Веза неурона у живим системима.

Прави неурони примају сигнале преко синапси лоцираних на дендритима или мембрани неурона (слика 14). Када су примљени сигнали довољно јаки (премашују одређени праг), неурон се активира и емитује сигнал кроз аксон (веза између неурона). Овај сигнал се може послати у другу синапсу и може активирати друге неуроне. На основу функционисања реалних неурона моделован је и рад вештачких неурона (слика 15). Они се у основи састоје од мноштва улаза (као што су синапсе), који се множе са тежинама (дају значај одговарајућим улазним сигналимa), а затим се сви улази обрађују помоћу одређене математичке функције која дефинише активацију неурона. Друга математичка функција израчунава излаз вештачког неурона (у зависности од одређеног прага).

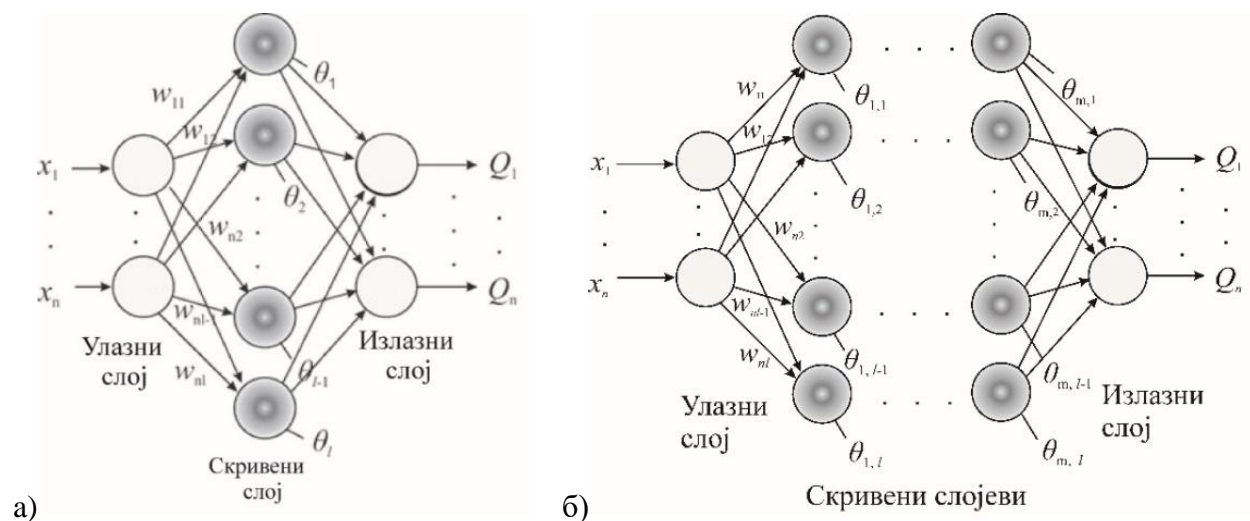


Слика 15. Структура вештачког неурона.

Неуронске мреже комбинују вештачке неуроне да би обрадили информације. Повезивањем неурона, слика 15, се могу добити различити типови вишеслојних неуронских мрежа, (тзв. Multilayer Feed-forward Network) где се види да су неурони једног слоја повезани са неуронима другог слоја. Слој где су смештени улазни подаци је улазни слој (input layer), затим постоји скривен слој (hidden layer) и слој неурона где су подаци са којима се врши повезивање односно излазни слој (output layer), слика 16.а. Једнослојне и вишеслојне НМ су развијене у истраживањима за различите процесе обраде сигнала за управљање процесима. Процес учења НМ са вишеслојним структурама, слика 16.б, представља дубоко структурно учење (deep learning) [77-79]. У овом раду су коришћене једнослојне неуронске мреже облика датог на слици 16а и наведена су искуства употребе вишеслојних неуронских мрежа.

Проласком података у једном смеру, одређивањем тежина уз примену активационе функције, могуће је алгоритмом са прилагођавањем тежина у оптимизацији градијента, тзв. повратном пропацијом (back propagation), поновним тренирањем доћи до жељених резултата на излазу [79,80].


Применом једноставне структуре неуронске мреже, уз надгледани тренинг, добија се алат којим се постиже минимизација како грешке предикције тако и временна предикције. Коришћењем регресије за решавање и анализу проблема са таквим мрежама могуће је не само смањити број улазних података, већ се то може урадити и применити на обичним, јефтиним и једноставним компјутерима и машинама (low-end machines).



Слика 16.а) Структура неуронске мреже састављене од повезаних неурона са више улаза и излаза, б) Вишеслојна неуронска мрежа.


3.2. Анализа теоријског модела фотоакустичког одзива полупроводника и развој неуронске мреже за фотоакустику

Пре него што анализирамо теоријски модел фотоакустичког одзива морамо се осврнути на појам плазма-дебелог и плазма-танког узорка, јер ћемо их у тексту доста често користити. Пошто је појам дебели или танки релативан, потребно је узети га за неку физичку величину. Код полупроводника је згодно узети величину звану дифузиона дужина фотогенерисаних носилаца $L_p = \sqrt{D_p \tau}$ где је D_p дифузивност мањинских носилаца и τ време живота у посматраном полупроводнику. За узорке силицијума који ће се користити у овом раду узеоћемо експерименталне вредности $D_p = 1.2 \times 10^{-3} \text{ m}^2 \text{ s}^{-1}$ и $\tau = 5 \times 10^{-6} \text{ s}$. На основу њих добија се да је дифузиона дужина вишка носилаца $L_p = 77.46 \mu\text{m}$. Ту вредност узимамо за границу плазма-дебелих и плазма-танких узорка. Плазма-дебели узорци су окарактерисани дебљинама већим од вредности L_p , а плазма-танки дебљинама мањим од L_p . Префикс „плазма“ односи се на фотогенерисане носиоце, које у полупроводницима можемо посматрати и као гас састављен од мноштва наелектрисаних честица, који поседује особину квазинеутралности [1,2,13,51].




Слика 17. Амплитуде и фазе укупног фотоакустичког сигнала плазма дебелих узорка у зависности од модулационе фреквенце, са променом дебљине од 100 до 1000 μm .

Приказом фотоакустичких сигнала плазма-дебелих узорка дебљина од 100 до 1000 μm на слици 17 и фотоакустичких сигнала плазма-танких узорка дебљина од 10 до 60 μm на слици 18, види се промена у облику сигнала. Код плазма-дебелих узорка се уочава седласт облик и за амплитуде и за фазе, док код плазма-танких узорка нема седластог облика [16,23,31]. Овом анализом смо закључили да су плазма-дебели узорци, због карактеристичног седластог облика, погоданији за обуку неуронске мреже.




Слика 18. Амплитуде и фазе укупног фотоакустичког сигнала плазма танких узорка дебљине од 10 до 60 μm .



Слика 19. Линије укупног фотоакустичког сигнала у фреквентном опсегу 20Hz-20kHz за вредности коефициента термалне дифузије $D_T = 9 \cdot 10^{-5} \text{m}^2 \text{s}^{-1}$ промењен у опсегу $\pm 10\%$ за силицијум дебљине 800 μm .

Наредном анализом можемо да покажемо осетљивост промене фотоакустичких сигнала на промене параметра термалне дифузивности D_T и термалне експанзије α_T која постоји и када посматрамо само једну дебљину узорка. Као пример навели смо узорке дебљине од $800\mu\text{m}$ са променом D_T и α_T у опсегу $\pm 10\%$ од литерарне вредности датих параметра узорка силицијума, и приказали их на сликама 19 и 20, респективно. Уочава се да постоји област промене облика сигнала за само једну дебљину узорка, због чега су сигнали плазма дебелих изорака погодни за обуку неуронских мрежа.




Слика 20. Линеје укупног фотоакустичког сигнала у фреквентном опсегу 20Hz-20kHz за вредности коефициента термалног ширења $\alpha_T = 2.6 \cdot 10^{-6} \text{K}^{-1}$ промењен у опсегу $\pm 10\%$ за силицијум дебљине $800\mu\text{m}$.

На основу ове анализе јасно је да ове промене параметара не мењају амплитуде и фазе плазма-дебелих узорака значајно, али је промена приметна, чак и у логаритамској скали. Због тога закључујемо да су области промене параметара довољни и погодни за обуку неуронских мрежа. Неуронске мреже могу на овај начин бити једнозначно обучене и могу бити добра основа за решавање инверзног фотоакустичког проблема.

3.2.1. Неуронске мреже у фотоакустици

Алгоритам учења заснован на грешци или тзв. supervised learning algorithms су алгоритми где се подаци стално пореде са спољашњим референтним податком. Циљ је да грешка која се јавља при учењу буде минимална. Вишеслојне перцептронске неуронске мреже су мреже

које могу да апроксимирају било коју функцију. Комбинацијом улазних, скривених и излазних неурона са адекватним тежинама и критеријумом за вредности прага се врши обучавање мреже за одређен процес (по аналогији са сликама 14,15). Најопштији опис добијања вредности једног излаза неурона ако је на улазу одређен вектор вредности (x_1, x_2, \dots, x_n) и додељене тежине (w_1, w_2, \dots, w_n) израчунава се производ вредности и одговарајуће тежине, тако да се одређује вредност $z = x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i$ којој се додаје вредност прага θ (Bias).



Слика 21. Дијаграм који представља добијање једног излаза $\sigma(m_i)$ једног неурона када су улазни подаци укупни фотоакустички сигнал δp_{total} (амплитуда и фаза) коме су додељене вредности тежина (w_1, w_2, \dots, w_n) . Дејство сигмоидалне функције у скривеном слоју након додавања вредности прага θ_i^1 .

У фотоакустици се најчешће користи регресија као класа проблема машинског учења (поглавље 3.1), у којој се повезује вредност фотоакустичког сигнала δp_{total} са одговарајућим параметрима испитиваног узорка, који су у овој тези D_T , α_T и l [81,82]. Структура мреже одговара проблематици која се решава. Улазни вектор садржи податке сигнала, а то су нормализована амплитуда $20 \log A_{total}(f_j)$ и фаза $\varphi_{total}(f_j)$ за $j = 1, \dots, 72$, слика 21, где се у свакој епохи израчунава Q_k излазног слоја, слика 22. Улазни подаци се кроз скривен слој множе са тежинама $w^1_{j,i}$, сумирају и додаје им се вредност bias-a θ_i^1 . Тиме се израчунава функција m_i једначина (55), која представља улаз за сигмоидалну функцију $\sigma(z) = (1 + e^{-z})^{-1}$, која има улогу нормализовања вредности у опсегу $[0,1]$:

$$m_i = \sum_{j=1}^{72} (w^1_{j,i} 20 \log A_{total}(f_j) + w^1_{72+j,i} \varphi_{total}(f_j)) + \theta_i^1, \quad i = 1, \dots, 50. \quad (55)$$

За израчунавање Q_k користи се једначина (56) за n_k , $k = 1, 2, 3$ као сума вишеструких производа тежина $w^2_{i,k}$, $k = 1, 2, 3$ и сигмоидалне функције примењене на m_i и bias-a θ_k^2 .

$$n_k = \sum_{i=1}^{50} w_{i,k}^2 \sigma(m_i) + \theta_k^2 = \sum_{i=1}^{50} w_{i,k}^2 (1 + e^{-m_i})^{-1} + \theta_k^2, \quad k = 1, 2, 3. \quad (56)$$

Активациона функција се израчунава над n_k , и њена се вредност користи за прорачун Q_k излазног слоја:

$$Q_k = \sigma(n_k) = (1 + \exp(-n_k))^{-1}, \quad k = 1, 2, 3. \quad (57a)$$

3.2.2. Алгоритам обуке

Алгоритам израчунавања је дат на слици 22 или следећим изразом:

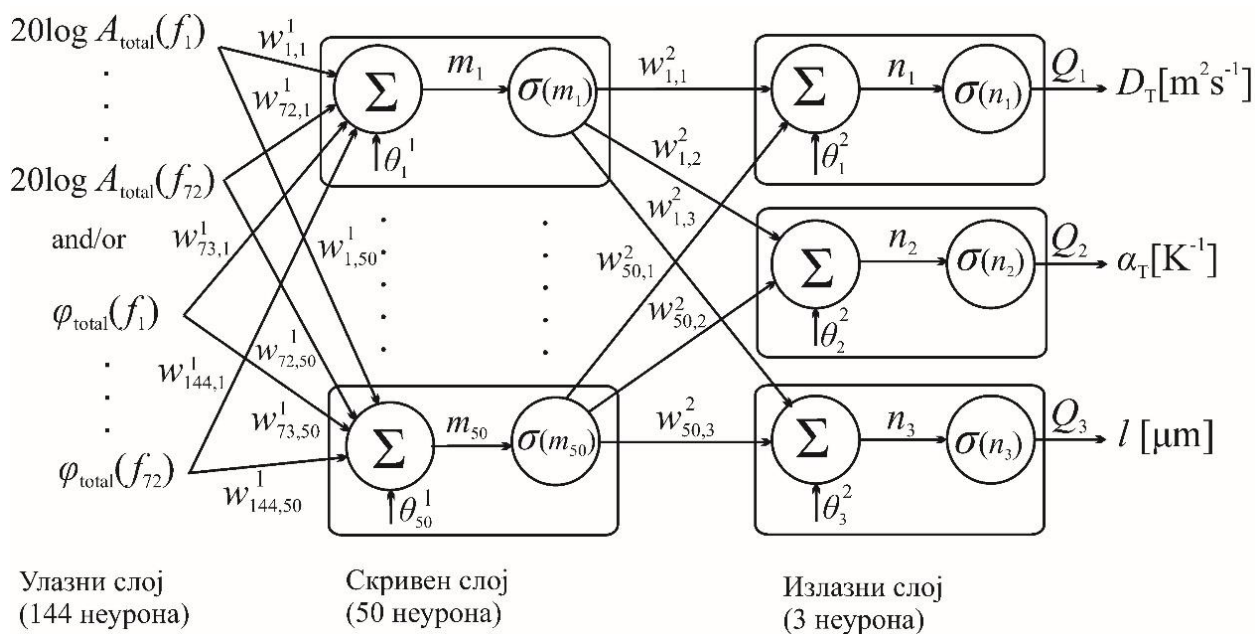
$$Q_k = \sigma \left(\sum_{i=1}^{50} w_{i,k}^2 \sigma \left(\sum_{j=1}^{72} (w_{j,i}^1 20 \log A_{\text{total}}(f_j) + w_{j+72,i}^1 \varphi_{\text{total}}(f_j)) + \theta_i^1 \right) + \theta_k^2 \right), \quad k = 1, 2, 3. \quad (57b)$$

Сигмоидална активациона функција $\sigma(z) = (1 + e^{-z})^{-1}$ поред тога што вредности целог опсега пребацује у опсег $[0, 1]$ има особину да се може представити преко извода $\sigma'(x)$.

$$\begin{aligned} \frac{d}{dx} \sigma(x) &= \frac{d}{dx} \left(\frac{1}{1 + e^{-x}} \right) = \frac{e^{-x}}{(1 + e^{-x})^2} = \frac{1 + e^{-x} - 1}{(1 + e^{-x})^2} = \\ &= \frac{1}{1 + e^{-x}} - \left(\frac{1}{1 + e^{-x}} \right)^2 = \sigma(x) - \sigma(x)^2. \end{aligned} \quad (58)$$

Извод сигмоидалне активационе функције се користи у процени током пропагације уназад као алгоритму у процени вредности грешке учења (Back Propagation). Након одређивања Q_k у свакој епохи током пропагације уназад се одређује средња квадратна грешка, (mean square error - mse), која представља суму квадрата разлике између вредности Q_k и циљане вредности T_k (targeted values), који представљају параметре узорка D_T , α_T и l [81-84]:

$$\text{mse} = E = \frac{1}{2} \sum_{k \in K} (Q_k - T_k)^2, \quad T_k \text{ је } D_T, \alpha_T \text{ и } l. \quad (59)$$



Слика 22. Неуронска мрежа за инверзно решавање фотоакустичког проблема. На улазном слоју су амплитуде и фазе, скривен слој има 50 неурона. Изразни слој су три параметара: термална дифузивност, експанзија и дебљина.

Овако дефинисанеа грешка, mse, приликом обуке неуронске мреже (слика 22) користи се да се израчуна како треба да се промене (ажурирају) тежине које су коришћене у прорачуну излазних вредности Q_k тако да грешка буде минимална. За то је потребно наћи извод грешке дате једначином (59) по тежини између слоја J и i на следећи начин $\frac{\partial E}{\partial w_{j,i}^1}$. Индексом J је означен број неурона улазног слоја, са i је означен број неурона скривеног слоја од 1,2,...50 и са $k = 1,2,3$ број неурона излазног слоја. Извод по тежинама се може разматрати за све тежине, од улазног слоја до скривеног и тежине од скривеног слоја до излазног слоја. Извод од скривеног слоја до излазног је:

$$\begin{aligned}
 \frac{\partial E}{\partial w_{jk}} &= \frac{\partial}{\partial w_{jk}} \frac{1}{2} \sum_{k \in K} (Q_k - T_k)^2 = (Q_k - T_k) \frac{\partial Q_k}{\partial w_{jk}} = \\
 &= (Q_k - T_k) \frac{\partial \sigma(x_k)}{\partial w_{jk}} = (Q_k - T_k) \sigma(x_k) (1 - \sigma(x_k)) \frac{\partial x_k}{\partial w_{jk}} = \\
 &= (Q_k - T_k) Q_k (1 - Q_k) Q_j = P_k Q_j .
 \end{aligned} \tag{60}$$

Параметар $P_k = (Q_k - T_k) Q_k (1 - Q_k)$ уведена је за излазни слој k :

$$\frac{\partial E}{\partial w_{jk}} = P_k Q_j. \quad (61)$$

Извод грешке по тежинама између улаза и скривеног слоја дат је изразом:

$$\begin{aligned} \frac{\partial E}{\partial w_{i,j}^1} &= \frac{\partial}{\partial w_{i,j}^1} \frac{1}{2} \sum_{k \in K} (Q_k - T_k)^2 = \sum_{k \in K} (Q_k - T_k) \frac{\partial Q_k}{\partial w_{i,j}^1} = \sum_{k \in K} (Q_k - T_k) \frac{\partial \sigma(x_k)}{\partial w_{i,j}^1} = \\ &= \sum_{k \in K} (Q_k - T_k) \sigma(x_k) (1 - \sigma(x_k)) \frac{\partial x_k}{\partial w_{i,j}^1} = \sum_{k \in K} (Q_k - T_k) Q_k (1 - Q_k) \frac{\partial x_k}{\partial Q_j} \frac{\partial Q_j}{\partial w_{i,j}^1} = \\ &= \frac{\partial Q_j}{\partial w_{i,j}^1} \sum_{k \in K} P_k w_{j,k}^1 = Q_j (1 - Q_j) \frac{\partial x_j}{\partial w_{i,j}^1} \sum_{k \in K} P_k w_{j,k}^1 = \\ &= Q_j (1 - Q_j) Q_j \sum_{k \in K} P_k w_{j,k}^1 = Q_j P_j. \end{aligned} \quad (62)$$

За скривен слој j важи да је $\frac{\partial E}{\partial w_{i,j}^1} = Q_j P_j$, тако да је $P_j = Q_j (1 - Q_j) \sum_{k \in K} P_k w_{j,k}^1$. На овај

начин неуронска мрежа током тренинга израчунава грешку у једној епохи. Да би грешка била минимална, неуронска мрежа, (слика 22), се враћа уназад (backpropagation), мењајући вредности тежина до скривеног слоја, и назад до улазних неурона. Затим се прорачун врши поново, са измењеним тежинама. Када неуронска мрежа дође до излазног слоја, на основу грешке се поново врши корекција тежина до улазног слоја. Циљ је да у коначном прорачуну излазних података добијемо минималну грешку. Тако на основу mse за сваки слој l може

одредити $P_l = \frac{\partial E}{\partial \theta}$, који одређује промену тежина. Промена прага се одређује из услова да

је: $\frac{\partial Q}{\partial \theta} = 1$. Тиме се вредности тежина w замењују са $w + \Delta w = w - \eta P_l Q_{l-1}$, док се праг θ

замењује са вредношћу $\theta + \Delta \theta = \theta + \eta P_l$.

Епоха је једна итерација којом алгоритам пролази кроз све податке. Резултат је израчунавање функције грешке и задавање вредности тежина (вектора тежина) тако да грешка буде минимална. Свака епоха има директну фазу где се рачунају за сваки узорак излазне вредности и повратне фазе у којој грешке са излаза иду ка улазном слоју.

Након одабира архитектуре неуронске мреже следи процес обучавања који као резултат има оптималне вредности тежина и коначну грешку која одређује перформансу

неуронске мреже. Комплексност проблема који се решава одређује архитектуру мреже док финим подешавањем подешавамо прецизност и оптимално време тренинга.

База података се дели на скуп за обучавање неуронске мреже, тест скупа и валидациони скуп. На основу података за обучавање одређују се вредности тежинских коефицијената. Из података валидационог скупа процењује се генерализационе способности мреже, и тест скуп одређује укупан учинак мреже.

Основу Лавенберг-Марквардовога алгоритма (Levenberg-Marquard) је дао Лавенберг (Kenneth Levenberg) 1944 године решавањем проблема Nonlinear Least Squares Minimization у коме је користио комбинацију метода опадајућег градијента (Steepest Descent) и Њутновог метода (Newton's method). Маркуард (Donald Marquard) 1963 је побољшао овај алгоритам коришћењем функција процене информација локалних кривих да би се измениле вредности функција. Лавенберг-Марквардов алгоритам се користи за налажење минимума функције које имају облик средње квадратне грешке mse [85-87]. Квадратну грешку можемо представити у облику (74). За минимизацију функције грешке се може увести појам помераја тежина $w - w_0$ између две суседне епохе, од тежина из претходне епохе w_0 до тежина текуће епохе w . И пошто је померај $w - w_0$ мали може се вектор грешке развити у Тејлоров ред (Taylor series):

$$\varepsilon(w) = \varepsilon(w_0) + Z(w - w_0), \quad (63)$$

где су матрични елементи $(Z)_{qi} = \frac{\partial \varepsilon^q}{\partial w_i}$, на основу које је функција грешке:

$$E = \frac{1}{2} \|\varepsilon(w_0 + Z(w - w_0))\|^2. \quad (64)$$

Нове тежине су $w = w_0 - (Z^T Z)^{-1} r(w_0)$, где је апроксимативни облик Hessian матрице $H = Z^T Z$. Када је померај релативно велики, користи се модификована функција грешке, где се уводи величина корака итерације λ (learning rate):

$$E = \frac{1}{2} \|(Q_k(w_0) - T_k(w_0)) + Z(w_1 - w_0)\|^2 + \lambda \|w_1 - w_0\|^2. \quad (65)$$

За велике вредности λ -а се прелази на стандардни метод опадајућег градијента, док се за мале вредности параметра λ прелази на Њутнов метод.

3.3. Избор погодног модела неуронске мреже

У овом поглављу дат је преглед претходних радова у примени неуронских мрежа у истраживањима фотоакустике, процена валидности постојећих резултата и анализа и дискусија избора погодног модела неуронске мреже како би се извршила што боља карактеризација полупроводничког материјала фотоакустиком [88-94].

У пракси се обично неуронске мреже обучавају на експерименталним сигналимa што припада области ненадгледаног машинског учења (поглавље 3.1). Међутим, како су у фотоакустици сигнали веома осетљиви на инструменталне утицаје, то би довело до тога да неуронске мреже обучавањем на експерименталним сигналимa унапред уносе велику непрецизност. Та непрецизност би се касније манифестовала у веома лошим резултатима предикције. Због тога је наш избор да се мреже обучавају на теоријским сигналимa, што по класификацији машинског учења припада надгледаном машинском учењу (поглавље 3.1.).

На основу искуства у фотоакустици гасова [87-89] показало се да мреже формиране на теоријским сигналимa без великих база могу да буду веома прецизне у предикцији параметра. Затим, показало се на основу резултата у класификацији [90] и детекцији инструменталног утицаја [34-36], да мрежа које су формиране на већим базама теоријских сигнала такође показују изузетну прецизност и поузданост.

3.3.1. Улазни слој

Број неурона у улазном слоју о коме смо већ говорили (поглавље 3.2.1), је врло осетљива тема и многи су се аутори бавили тиме. У фотоакустици гасова радило се са 21 до 28 неурона у улазном слоју [87,88], док се у детекцији утицаја инструмената користио много већи број, који се кретао од 2×151 [35], затим од 2×200 [34] и 148 [90]. Овакав избор броја неурона улазног слоја је био одређен на основу захтева за прилагођеност експерименталним условима прикупљања података или постизању добре прецизности. То нас је навело на следеће разматрање које је утицало на одабир броја неурона илазног слоја за обуку мрежа коришћених у овој тези.

Вредности које се задају неуронима улазног слоја (слика 21 и 22) су вредности фотоакустичког сигнала. Неопходно је узети у обзир да вредности фотоакустичких сигнала

које се представљају мрежи на улазу, било за обуку или предикцију, буду на истим фреквенцијама и у истим фреквентним корацима као и у експерименту. Уколико постоји непоклапање фреквентних корака и фреквенција тренинга мреже и сигнала за предикцију, могуће је превазићи тај проблем међусобним прилагођавањем података интерполацијом у задатом фреквентном домену.

За мреже приказане у овој тези извршили смо прилагођавање и одабир фреквентног корака и фреквенција обуке неуронске мреже на основу фреквентног корака и фреквенција експеримента, што нас је довело до избора 72 вредности за фреквенце у фотоакустичком опсегу од 20 Hz до 20 kHz. Тај број фреквентних корака одговара броју фреквентних тачака амплитуде и фазе у стандардном мерењу фотоакустичких сигнала методом отворене фотоакустичке ћелије (поглавље 2.2), у којима се фреквенција генерише еквидистантно у логаритамској скали. Одабиром 72 фреквентна корака за амплитуду и за фазу одређен је максималан број неурона за тренинге мрежа – 144 (72x72).

Наше анализе су показале да се код мрежа код којих су спрегнуте амплитуде и фазе намеће потреба додатне обраде улазних података амплитуда и њихово прилагођавање вредностима улазног вектора фазе. Разлог за то је промена вредности амплитуда фотоакустичког сигнала, у датом фреквентном опсегу, за неколико редова величина док се фазе мењају између -180 и 180 степени. Уколико се не изврши прилагођавање улазног вектора, губи се на прецизности и поузданости мреже. Због тога смо амплитуде фотоакустичког сигнала нормализовали на вредности $20 \log(A_i), i = 1,2,3$ које су поредиве са прилагодили вредностима фаза, (слика 22). Тако спрегнуте вредности нормализованих амплитуда и фаза смо користили за обуку неуронске мреже.

Након прилагођавања броја улазних неурона експерименталном мерењу фотоакустичког сигнала одабиром 72 фреквентних корака, поставља се и додатно питање, да ли је могуће одабрати и мањи број улазних неурона тако да мрежа не изгуби на прецизности. Погодност коју би остварили смањењем броја улазних неурона је смањивање броја неопходних фреквентних корака експерименталног мерења. То би довело до тога да укупно време које је потребно за прикупљање експерименталних података (мерење фотоакустичког сигнала) буде краће. У овом раду смањење улазног вектора рађено је обуком мрежа само са амплитудама (72) или само са фазама (72).

3.3.2. Скривени слој

Избор структуре неуронске мреже утиче на начин обуке мреже током једне епохе (поглавље 3.1. слике 21 а. и б.) због чега је време потребно за њен тренинг различито. Структура мреже је одређена бројем скривених слојева и бројем неурона у њима. Поред времена обуке неуронске мреже, као захтев за даљу употребу неуронске мреже намеће се њена прецизност и време предикције параметара.

Постоје различита искуства у формирањима вишеслојних мрежа. Једно од њих каже да при промени броја слојева и броја неурона у слојевима нпр. (28-10-3), (28-15-3) и затим (28-7-7-3), долази до повећања времена предикције од 8.76 на 9.42 и 11.33 μs , респективно [64]. Друго искуство говори да се повећањем броја скривених слојева и избором другачијег броја неурона у скривеном слоју, то време може да се редукује за $\sim 1 \mu\text{s}$ [91]. Ово нам говори да промена броја скривених слојева и броја одабраних неурона у скривеним слојевима доводи до промена у времену предикције. Због тога смо у овој тези изабрали најједноставнији модел (слика 22) са једним скривеним слојем, са надом да ће нам омогућити предикцију у реалном времену.

3.3.3. Излазни слој

Одабир броја неурона излазног слоја је одређен бројем параметра узорка које сматрамо да су потребни за карактеризацију узорка. Постоје различита искуства у броју одабраних параметара за које би мрежа давала њихову предикцију. Тај број је различит и креће се од једног до пет параметара, мада теоријски тај број може да буде и већи. Његово одређивање је везано за решавање одређеног проблема. Тако смо на основу анализе у поглављу 3.2 одабрали три параметра који су нам битни у одређивању компоненти укупног фотоакустичког сигнала (једначина (49)) и са којима можемо да извршимо термоеластичну карактеризацију полупроводничких узорака.

Да би неуронска мрежа била прецизнија урадили смо прилагођавање опсега вредности параметара дифузивности, експанзије и дебљине у излазном слоју мрежа нормализацијом, тако да вредности параметара буду међусобно упоредиве тј. истог реда величине [44,48,49].

Литература (Поглавље 3)

- [61] G. Bal, A. Jollivet, V. Jugnon Inverse Transport Theory of Photoacoustics, <https://www.stat.uchicago.edu/~guillaumbal/PAPERS/PAT-TR-IP-09.pdf>
- [62] A. Tarantola, Inverse Problem Theory - Institut de Physique du Globe [ISBN 0-89871-572-5](#)
- [63] M. V. Nešić, P. Gusavac, M. N. Popović, Z. N. Šoškić, S. P. Galović, Thermal memory influence on the thermoconducting component of indirect photoacoustic response. *Phys Scri* T149 014018 (2012) <https://doi.org/10.1088/0031-8949/2012/T149/014018>
- [64] M. Nestic, M. Popovic, and S. Galovic, Developing the Techniques for Solving the Inverse Problem in Photoacoustics, *Atoms* 7(1), 24 (2019); <https://doi.org/10.3390/atoms7010024>
- [65] Y. S. Abu-Mostafa, M. Magdon-Ismail, and H.-T. Lin, Learning From Data. AML Book, 2012. **ISBN-10: 1600490069**
- [66] S. Russell and P. Norvig, Artificial Intelligence A Modern Approach. Prentice Hall 578 (2009) [ISB 978-0-13-604259-4](#)
- [67] I. H. Witten and E. Frank, Data Mining Practical Machine Learning Tools and Techniques. *Elsevier Ltd*, (2005).
- [68] N. Vidič, Primena mašinskog učenja u verifikaciji softvera, [master rad](#), Matematički Fakultet, Univerziteta u Beogradu
- [69] S. Ding, H. Li, C. Su, J. Yu, and F. Jin, Evolutionary artificial neural networks: a review, *J. Artif. Intell. Rev.* (2011) 1–10 <https://doi.org/10.1007/s10462-011-9270-6>
- [70] D. Kriesel, A brief Introduction on Neural Networks (2007)
- [71] P. Tino, L. Benuskova, and A. Sperduti, Artificial Neural Networks Models, 8 3 455–472 (1997)
- [72] W. Duch, G. H. F. Diercksen, Neural networks as tools to solve problems in physics and chemistry, *Comput. Phys. Commun.* 82 91-103(1994) [https://doi.org/10.1016/0010-4655\(94\)90158-9](https://doi.org/10.1016/0010-4655(94)90158-9)
- [73] N. Artrith, A. Urban, An implementation of artificial neural-network potentials for atomistic materials simulations: Performance for TiO₂, *Comput. Mater. Sci* 114 135-150 (2016) <https://doi.org/10.1016/j.commatsci.2015.11.047>
- [74] J. Zupan, Artificial Neural Networks (ANNs) *Basic Concepts and Methods*, *J. Cheminformatics* 438-452 (2018) DOI: [10.1002/9783527816880.ch11_02](https://doi.org/10.1002/9783527816880.ch11_02),
- [75] Ž. Čojbašić, V. Nikolić, I. Ćirić and Lj. Čojbašić, Computationally Intelligent Modelling and Control of Fluidized Bed Combustion Process *THERM SCI* 15 321 (2011) DOI: [10.2298/TSCI101205031C](https://doi.org/10.2298/TSCI101205031C)
- [76] C. Glorieux and J. Thoen, Thermal depth profile reconstruction by neural network recognition of the photothermal frequency spectrum, *J. App. Phys.* 80 11 6510–6514 (1996) <https://doi.org/10.1063/1.363670>
- [77] A. E. Shahat, Artificial Neural Network (ANN), Smart & Energy Systems Applications *Scholar Press Publishing* (2014) [ISBN: ISBN-10: 3639711149 | ISBN-13: 978-3639711141](#)
- [78] B. Venkateswaran and G. Ciaburro, Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles *Packt Publishing* (2017) [ISBN-10: 1788397878, ISBN-13: 9781788397872](#)

- [79] D. Karaboga, B. Akay, *APPL MATH COMPUT* **214** 1-108 (2009) [ISSN: 0096-3003](#)
- [80] D. E. Rumelhart, G. E. Hinton and R. J. Williams, Learning representations by back-propagating errors, *Nature* **323** 6088:533–536 (1986) <https://doi.org/10.1038/323533a0>
- [81] A. Graves, Supervised sequence labelling with recurrent neural networks *SSBM* 385(2012) [ISBN 978-3-642-24797-2](#)
- [82] K.L. Du and M.N.S. Swamy, Search and Optimization by Metaheuristics (AG Switzerland:Springer) (2016) <https://doi.org/10.1007/978-3-319-41192-7>
- [83] C. M. Bishop, Neural networks and their applications, Rev. Sci. Instrum. 65 1803 (1994) <https://doi.org/10.1063/1.1144830>
- [84] G. Dreufus, Neural Networks: Metodology And Applications, Berlin: Springer (2005) [ISBN 978-3-540-28847-3](#)
- [85] K. Levenberg, A method for the solution of certain problems in least squares, Quart. Appl. Math. 2 [164–16, \(1944\)](#)
- [86] D. W. Marquard, An Algorithm for Least-Squares Estimation of Nonlinear Parameters Journal of the Society for Industrial and Applied Mathematics, 11(2), 431–441, <https://doi.org/10.1137/0111030>
- [87] M. Lukic, Analiza atmosfernih polutana inteligentnom impulsnom fotoakustikom, Doktorska disertacija [HTTP://NARDUS.MPN.GOV.RS/123456789/9527](http://NARDUS.MPN.GOV.RS/123456789/9527)
- [88] M. Lukić, Ž. Čojbašić, M. D. Rabasović, D. D. Markushev, D. M. Todorović, Computational intelligence based simultaneous determination of the spatial profile of the laser beam and vibrational-to-translational relaxation time by pulsed photoacoustics, FU Phys Chem Tech (2012) [10:1-12.](#)
- [89] M. Rabasović, D. Markushev, Ž. Čojbašić, M. Lukić, D. Todorović, Spatial laser beam determination by pulsed photoacoustics: detection radius/signal wavelength approximation, *Phys. Scr.* T157:014058 (6pp) (2013) [DOI:10.1088/0031-8949/2013/T157/014058](#)
- [90] M. J. Pavlovic, A. Kupusinac and M. Popovic: Classification model for microphone type recognition, Proceedings of 11th International scientific conference Science and Higher Education in Function of Sustainable Development – SED (2019) [ISBN 978-86-83573-95-0](#), <http://arxiv.org/abs/1906.09958>
- [91] M. I. Jordovic Pavlovic, D. D. Markushev, A. D. Kupusinac, et al. Deep Neural Network Application in the Phase-Match Calibration of Gas–Microphone Photoacoustics. *Int J Thermophys* 41, 73 (2020) <https://doi.org/10.1007/s10765-020-02650-7>
- [92] M. Lukić, Ž. Čojbašić, M. Rabasović, D. Markushev, Computationally intelligent pulsed photoacoustics, MEAS SCI TECHNOL 25:125203 (2014) [DOI:10.1088/0957-0233/25/12/125203](#)
- [93] M. Lukic, Ž. Cojbašic, M. D. Rabasovic, D. D. Markushev, D. M. Todorovic. Laser Fluence Recognition Using Computationally Intelligent Pulsed Photoacoustics Within the Trace Gases Analysis. *Int J Thermophys*, 38:165 (pp 12) (2017) [DOI: 10.1007/s10765-017-2296-5](#)
- [94] M. N. Popovic, D. Furundzic, and S. P. Galovic, Photothermal Depth Profiling Of Optical Gradient Materials By Neural Network, *Publ. Astron. Obs.* Belgrade No. 89 (2010) [147-150](#)

4. РЕЗУЛТАТИ И ДИСКУСИЈА

4.1. Обука мреже

Идеја примене неуронских мрежа у инверзном решавању фотоакустичког проблема полупроводника се заснива, како је објашњено у претходној глави, на томе да се формира таква неуронска мрежа која може са великом прецизношћу да из фотоакустичких сигнала одреди физичке параметре посматраног узорка. Осим термоеластичне карактеризације, параметри одређени на овај начин су враћени у теоријски модел како би се одредили доминантни ефекти у одређеним фреквентним доменима и тако извршила додатна анализа транспортних процеса и омогућила додатна карактеризација односно одређивање додатних физичких својстава узорака.

Прецизност неуронске мреже у највећој мери зависи од њене обуке која се заснива на одабиру релевантне базе података за тренинг, тест и валидацију. База података са којима се мрежа обучава, коришћена у овом раду, формирана је на фотоакустичким сигнаlima добијеним из теоријског модела композитног клипа у фреквентном опсегу од 20Hz до 20kHz.

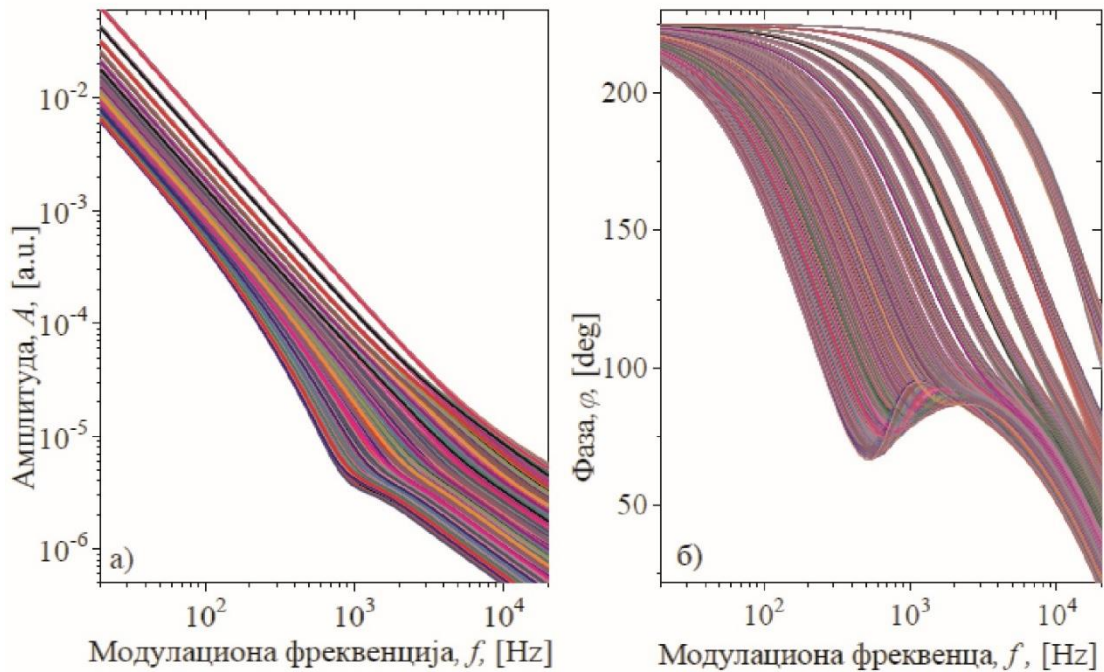
4.1.1. Општи принципи

Општи принципи који су усвојени у овом раду садрже се у специфичном одређивању структуре мреже и одређивању базе фотоакустичких сигнала за обуку, тест и валидацију. Као специфичну структуру неуронских мрежа употребили смо једноставне мреже са једним скривеним слојем, улазним слојем у коме број неурона одговара фреквенцама фотоакустичког сигнала коришћеним у експерименту, и излазним слојем са три неурона који одговарају трима карактеристичним параметарима испитиваног полупроводника.

Да би истестирали различите неуронске мреже, за податке базе су одабрани амплитудно фазни сигнали, само амплитудни или само фазни сигнали плазма-дебелих узорака [2,44,48,49]. У припреми базе подразумевана је и нормализација података, којом је усклађен опсег промене вредности података базе [95,96].

Уопштено говорећи да би обучили мреже у фреквентном домену од 20 до 20kHz направљена је база фотоакустичких сигнала за силицијума n-типа на основу теоријског модела (поглавље 2, једначина (49)). База фотоакустичких сигнала је добијена променом параметара термалне дифузивности D_T и термалног ширења α_T у опсегу 10% са кораком

1.25% , око вредности чистог, недопираног силицијума ($D_T = 9 \cdot 10^{-5} \text{ m}^2 \text{ s}^{-1}$ и $\alpha_T = 2.6 \cdot 10^{-6} \text{ K}^{-1}$). Дебљине узорка l мењане су у опсегу $l = (1-10) \cdot 10^2 \mu\text{m}$ са кораком $50 \mu\text{m}$. Остали параметри који су коришћени при формирању сигнала сматрани су константним и наведени су у Табели 1 [2,51,54].




Слика 23. Симулација ФА сигнала са којима је обучена НМ: а) амплитуде и б) фазе плазма дебелих узорка силицијума n -типа.

На овај начин је добијено укупно 5491 амплитуда и исто толико одговарајућих фаза фотоакустичких сигнала приказаних на слици 23, који чине базу података за обуку неуронске мреже. Циљ је да се са оваквом базом неуронске мреже буду поуздане, брзе и тачне у предикцији D_T , α_T и l допираних силицијумских узорка.

Најједноставија структура неуронске мреже са једаним улазним, једаним скривеним и једаним излазним слојем (поглавље 3.3) приказана је на слици 24. У улазном слоју (поглавље 3.2.1, 3.3.1) је сваки фотоакустички сигнал одређен са по 72 вредности за амплитуда и фазу (Input layer, 144 neurons), у еквидистантном фреквентном домену у логаритамској скали. Сваком фотоакустичком сигналу одговара једна комбинација вредности параметара излазног слоја D_T , α_T и l (Output layer, 3 neurons). Пре обуке неуронске мреже је издвојена свака 50-а линија (укупно 110 линија) за независтан тест, а од преосталог броја 80% за тренинг, 10% (538 линија) за валидацију и 10% (538 линија) за тест неуронске мреже. Структура, обука, тест и валидација мреже рађени су у програму MatLab18 (слика 25) [96,97].


Табела 1. Вредности параметра силицијума који су коришћени за фитовање, [2,47,51,54].

Si sample bulk parameters in the case of optical excitation power $P_0 = 10 \times 10^{-3} \text{W}$			
Густина	$\rho = 2.33 \times 10^3 \text{ kg} \cdot \text{m}^{-3}$	Дифузивност носилаца	$D_p = 1.2 \times 10^{-3} \text{ m}^2 \cdot \text{s}^{-1}$
Оптичка рефлексивност	$\gamma_R = 0.35$	Брзина површинске рекомбинације предње стране узорка	$s_1 = 2 \text{ m} \cdot \text{s}^{-1}$
Оптички коефициент апсорпције	$\beta = 2.58 \times 10^5 \text{ m}^{-1}$	Брзина површинске рекомбинације задње стране узорка	$s_2 = 24 \text{ m} \cdot \text{s}^{-1}$
Термална дифузивност	$D_T = 0.9 \times 10^{-4} \text{ m}^2 \cdot \text{s}^{-1}$	Young's modulus	$E = 1.31 \times 10^{11} \text{ N} \cdot \text{m}^{-2}$
Енергија ексцитације	$\varepsilon = 1.88 \text{ eV}$	Линеарна термална експанзија	$\alpha_T = 2.6 \times 10^{-6} \text{ K}^{-1}$
Енергија процепа Si	$\varepsilon_g = 1.11 \text{ eV}$	Коефициент електронске деформације	$d_n = -9.0 \times 10^{-31} \text{ m}^3$
Време живота фотогенерисаних носилаца	$\tau = 5.0 \times 10^{-6} \text{ s}$	Таласна дужина светлости ласерске диоде	$\lambda = 660 \text{ nm}$
Адијабатска константа за ваздух	$\gamma = 1.4$	Термална проводност	$k = 150 \text{ Wm}^{-1}\text{K}^{-1}$



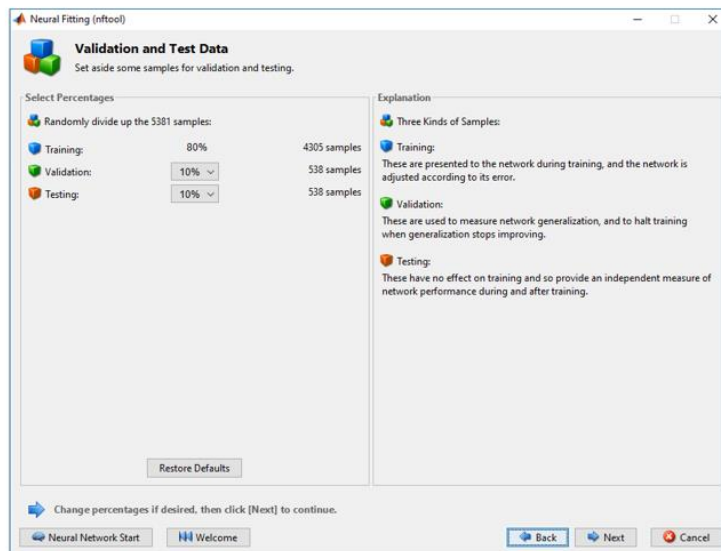
Слика 24. Приказ неуронске мреже са једним скривеним слојем која је коришћена за обуку и тестирање амплитуда и фаза ФА сигнала силицијумских узорка.

Промене амплитуде сигнала (слика 23) у датом фреквентном опсегу су износиле неколико редова величине, док су промене фаза биле у опсегу -180 до 180 степени. Велике разлике у опсегу промена улазних података (амплитуде и фазе) доводе до мање прецизности и поузданости мреже, због чега се мора изврши прилагођавање улазних параметара неком од метода нормализације (поглавље 3.3.1). Логичан след је био да се, у овом раду, подаци улазног слоја (Input layer) прилагоде тако што су се вредности амплитуда прилагодили вредностима фаза нормализацијом помоћу функције $20\log(A_i)$, $i = 1,2,3$. На тај начин је опсег промена вредности амплитуда постао једнак опсегу промена вредности фаза [44,48,49] (слика 25).



Слика 25. Симулација ФА сигнала са којима је обучена НМ: а) нормализоване амплитуде и б) фазе плазма-дебелих узорака силицијума n-типа.

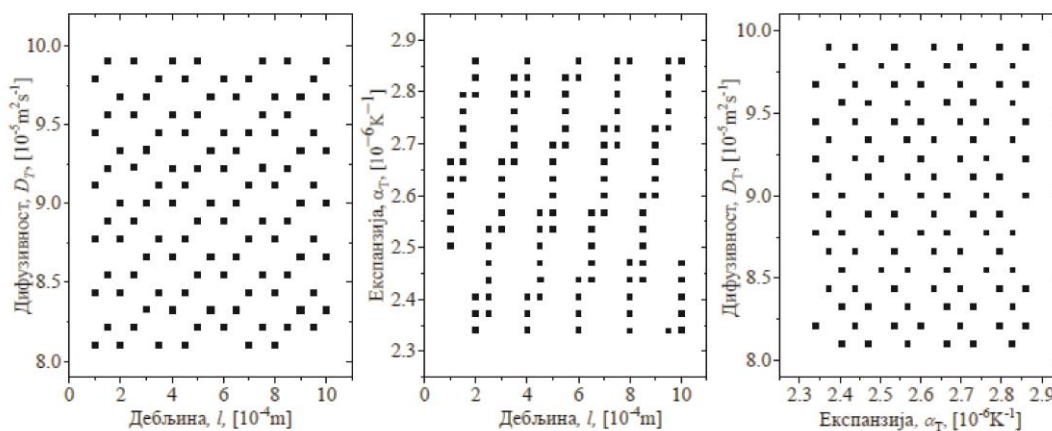
На основу искуства (поглављу 3.3.2) једном скривеном слоју је придружено 50 неурона (Hidden layer, 50 neurons, слика 24). Време обуке backpropagation методом (поглавље 3.2.1), састојало се из низа епоха, и у просеку се кретало и до неколико сати. Коришћена је сигмоидална активациона функција и Levenberg–Marquardt-ов алгоритам (поглавље 3.2.1).



Слика 26. MatLab Neural Fitting.

4.1.2. Одабир опсега вредности параметара

Избор вредности параметра који је дефинисан у претходном поглављу у највећој мери је одређен тиме да се преплитање сигнала, тј. неједнозначност вредности амплитуде и фазе сведе на најмању могућу меру. То нам омогућава да се обуком неуронске мреже на оваквим сигналима постигне максимална прецизност и поузданост у предикцији. Један од начина на који може да се провери добар избор вредности параметара јесте провера да ли су параметри међузависно груписани или хомогено распоређени у задатим областима промене. Показало се да је при нехомогено распоређеним подацима, потребно да се изврши додатна анализа и алгоритамска филтрација података [98,99] тако да подаци буду хомогено распоређени у области њихове промене.




Слика 27. Међусобна зависност параметра предикције неуронске мреже на 110 сигнала независног теста.

Из тог разлога смо овде приказали на слици 27, зависност параметара података D_T , α_T и l , независног теста, који има 110 сигнала а представља сваки 50-и сигнал обуке узет из основне базе од 5381 сигнала [44,48,49]. Хомогене расподеле са ове слике указују на то да је непотребна додатна анализа, тестирање или филтрирање података, јер је преклапање података сведено на минимум.


Другачије речено, прецизношћу и поузданошћу овако добијене неуронске мреже је показано да за обучавање и тестирање неуронске мреже нису неопходне велике базе података, већ да је неопходан добар и правилан избор базе података. То се јасно може видети у одабиру само по 6-7 вредности параметара на слици 27 за сваку међусобну зависност.

4.1.3. Одабир најпоузданије мреже

Да би одредили мрежу која нам даје најпоузданије и најпрецизније параметре тестирали смо ефикасност мрежа у зависности од типа података у улазном слоју. За такво поређење су обучене три неуронске мреже исте структуре (слика 24), са истим бројем података у улазној бази (5491 фотоакустичких сигнала): а) мрежа ANN1 имала је у улазном слоју и амплитуде и фазе, б) мрежа ANN2 имала је само амплитуде у улазном слоју и в) мрежа ANN3 имала је само фазе у улазном слоју. Разлика се састојала у томе што је мрежа (ANN1) у улазном слоју имала број неурона 144 што се може видети на слици 28, а мреже ANN2 и ANN3 су имале у улазном слоју 72 неурона, што се може видети на слици 29. Број неурона у скривеном слоју за све три мреже је био 50, а број излазних неурона је у сва три случаја био исти, 3, и представља параметре полупроводника D_T , α_T и l .

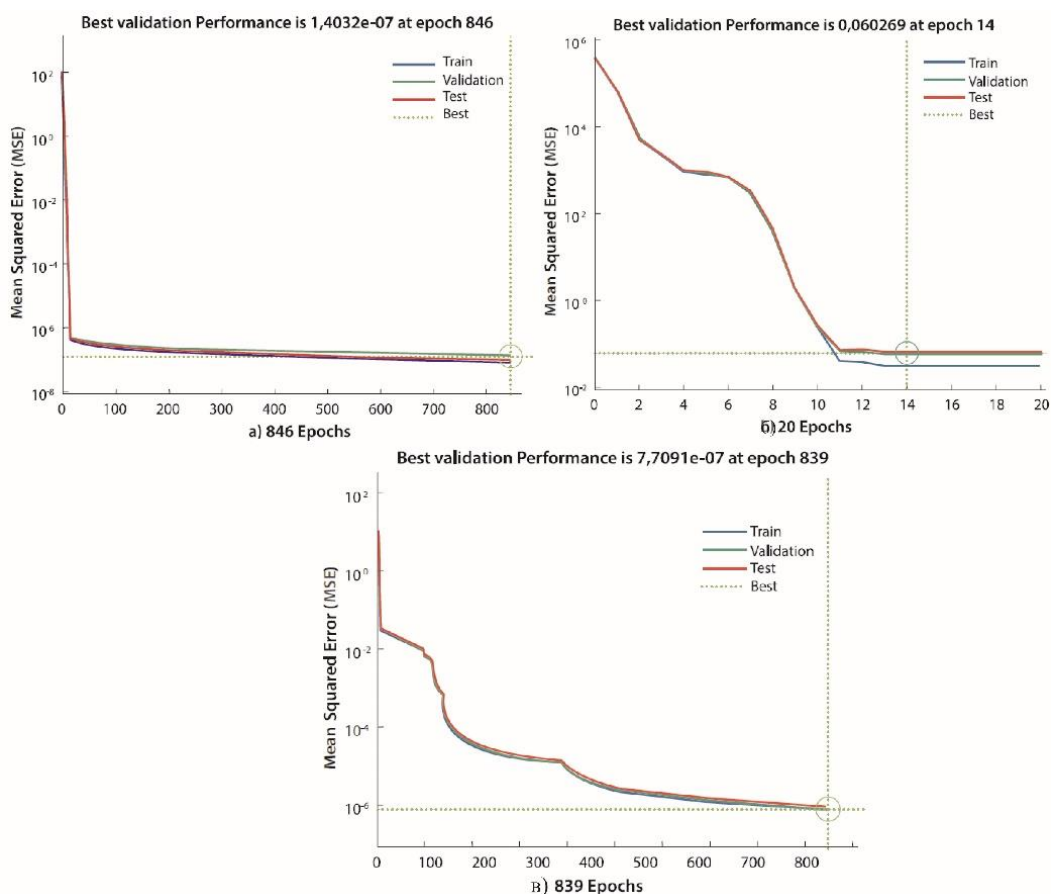


Слика 28. MatLab18 са 144 неурона на улазном слоју, 50 неурона скривеног и 3 неурона излазног слоја, коришћен за ANN1.



Слика 29. MatLab18 са 72 на улазном слоју, 50 неурона скривеног и 3 неурона излазног слоја, коришћен за ANN2 и ANN3.

Резултати обуке ових мрежа су приказани на слици 30, за: а) ANN1, б) ANN2 и в) ANN3, где су приказане вредности броја епоха потребних да се достигне минимална вредност средњих квадратних грешака – mse, средња вредност квадрата разлике вредности параметара D_T , α_T и l у тој епохи и крајње очекиване вредности параметара (једначина (59)). Поредићи ове вредности јасно је да су највећу прецизност показале мреже ANN1 (mse = 1.4032×10^{-7}) и ANN3 (mse = 7.7091×10^{-7}) (слика 30а) и в)). Време обуке ове две мреже било је приближно исто (~850 епоха). Оно што треба имати на уму то је да мрежа ANN1 достиже вредност mse $\sim 10^{-7}$ већ у неколико епоха, док у случају мреже ANN3 то није случај: потребно је неколико стотина епоха да ова мрежа достигне приближно исту вредност mse [44,100].



Слика 30. Обука НМ мрежа на основу смањења вредности mse са епохама обуке: а) ANN1, б) ANN2 и в) ANN3.

Током обуке неуронске мреже само на амплитудама ANN2, већ након 14 епоха мрежа постиже своју најбољу вредност mse од 0.060269, што се види на слици 30, б). Интересантно је приметити да даљом обуком мреже, кроз већи број епоха вредност mse остаје иста.

Табела 2. Грешке неуронских мрежа, максимална (%) и средња (%) које се јављају при предикцији три параметара D_T , α_T и l са три различите неуронске мреже трениране а) амплитудама и фазама, б) амплитудама и в) само фазама фотоакустичких сигнала. Грешке су одређене за независни тест.

Тип мреже	Мах грешка (%)			Средња грешка (%)			бр епоха
	D_T	α_T	l	D_T	α_T	l	
ANN1	0.1828	0.0506	0.0250	0.0019	0.0018	0.0002	846
ANN2	11.1252	4.9230	1.0978	2.5410	0.6842	0.0920	20
ANN3	0.0822	0.1928	0.0679	0.0083	0.0275	0.0082	839

Јасно се види, на основу Табеле 2, да је ANN1 најпрецизнија када посматрамо сва три параметра заједно. Највеће грешке прави амплитудна мрежа ANN2 при предикцији сва три параметра, док мрежа ANN3 прави добре предикције тражених параметара, али не као ANN1. Иако мрежа ANN3 даје добре предикције тражених параметара (најбоље за D_T) ми смо се одлучили за мрежу ANN1 као најпоузданију мрежу јер најмање грешки када посматрамо сва три параметра заједно.

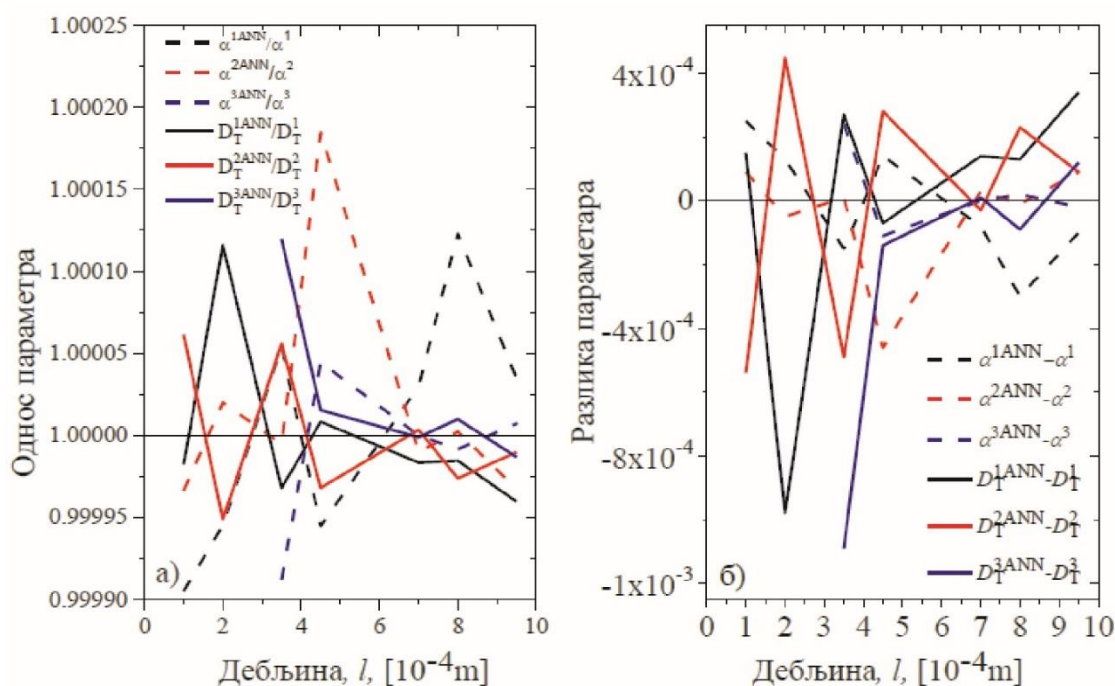
Интересантно је приметити да, упркос очекивању заснованом на теоријском моделу који показује да и амплитуде и фазе зависе од истих параметара, та зависност није линеарна. Резултати које смо добили са различитим неуронским мрежама показују да су амплитуде и фазе спрегнуте и да само њиховом симултаном анализом могу да се добију најпоузданији и најпрецизнији резултати. Амплитуде или фазе, саме за себе, дају добре резултате само у ограниченом броју случајева. Овај закључак је посебно важи за експерименте, у којима су се до сада неки аутори искључиво оријентисали на израчунавање параметара полупроводника само из амплитуда или само из фаза. Треба такође имати у виду да мања прецизност ANN2 и ANN3 не долази само због редукције улазног вектора већ и због због спрегнутости амплитуде и фазе.

Након обуке ANN1 је била у стању да скоро тренутно ($\sim 7.1 \mu s$) препозна амплитуду и фазу ФА сигнала и њима одговарајуће вредности тражених параметара са великом прецизношћу. Тачност у предикцији сигнала не прелази стоти део процента. Поређењем вредности предикције сигнала којима је тестирана и тренирана неуронска мрежа и вредности које препознаје мрежа а њима није тренирана се веома мало разликују.

4.1.4. Тест поузданости одабране мреже

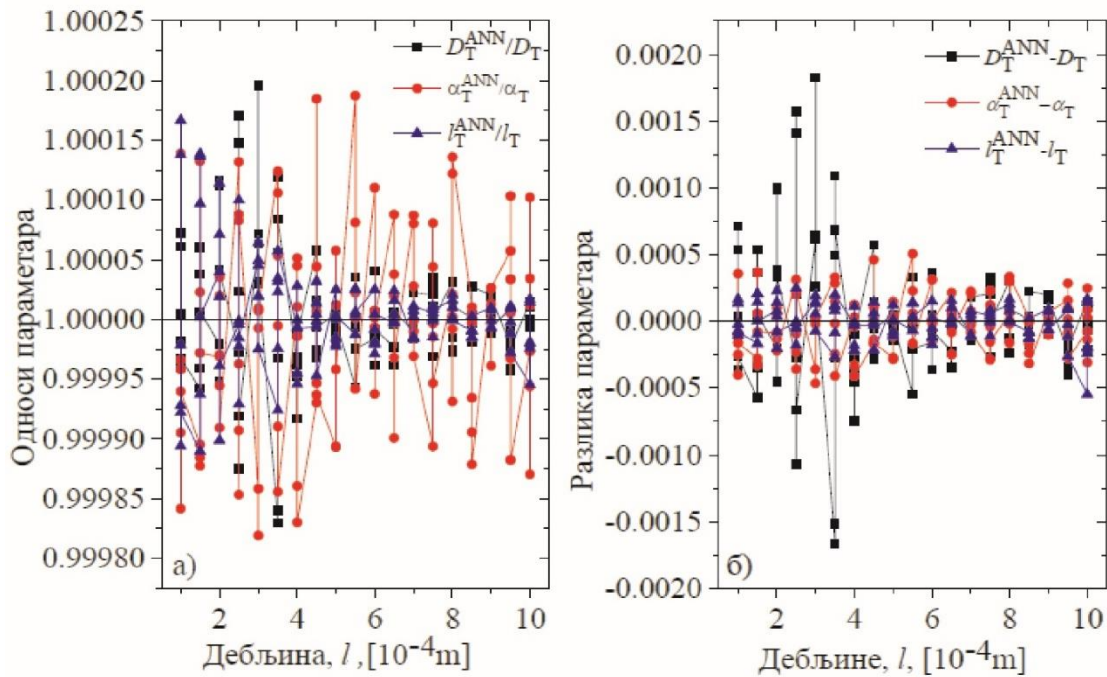
На основу резултата из претходног поглавља одабрали смо мрежу ANN1 као најпоузданију мрежу. У овом поглављу ћемо извршити њен тест на 110 фотоакустичких сигнала, који нису учествовали у тренингу мреже, чија је хомогеност приказана на слици 27 за вредности D_T

, α_T и l . Тест поузданости мреже се огледа у сагледавању прецизности предикције неуронске мреже на целом опсегу промене параметара. Мрежа ANN1 је дала предикцију и одредила параметре D_T^{ANN} , α_T^{ANN} и l^{ANN} , са којима су одређени а) односи и б) разлике грешака предикције параметара сигнала. Овде су грешке током предикције дате у зависности од промене дебљине узорка (слика 31 и 32).



Слика 31. Графици а) односа и б) разлика параметара D_T^{ANN} и α_T^{ANN} који смо добили од неуронске мреже и параметара D_T и α_T независног теста сигнала са којима се мрежа није обучавала. Пуна линија је коришћена за дифузивност D_T и испрекидана линија за коефициент термалног ширења α_T .

Величина грешака, која је мања од 1% за све параметре (слика 31 и 32), говори о поузданости неуронске на целом опсегу промене параметара. За појединачне параметре, можемо уочити специфичне карактеристике мреже, тј да мрежа највише греша за танке узорке у предикцији термалне дифузивности (црна линија) и дебљине узорака (плава линија, слика 32 и 33)[101,102]. Грешка линеарне експанзије (црвена линија) можемо да кажемо да је равномерна на целом опсегу дебљина. Овакво понашање грешака значи да је мрежа добро обучена и поуздана јер прати теоријски модел.



Слика 32. График зависности а) односа и б) разлике промене коефициента термалне дифузије (црна крива), промена коефициента термалног ширења (црвена крива) и промене линеарне димензије узорка (плава крива) у зависности од дебљине узорка.


4.1.5. Тест мреже са различитим кораџима промене параметара

Након добре прецизности коју је показала неуронска мрежа ANN1 у предикцији параметара l , D_T и α_T за независан тест (Табела 2), одлучили смо се да тестирамо мрежу на другачијим сигналимa. Формирана је база која садржи 22 фотоакустичка сигнала, чије су вредности параметра дифузивности, експанзије и дебљине углавном насумичне, и чије су вредности дате у Табели 3. Облици сигнала који су приказани мрежи су добијени нумеричком симулацијом (једначина (49)), и не поклапају се ни са једним сигналом из базе обуке и независног теста. Параметри тих 22 сигнала налазе се унутар опсега промене параметара коришћених за генерисање базе, али су ван корака њихових промена. Након предикције мреже ANN1, одређени су параметри који су приказани у Табели 3, и дате су максималне (%) и средње (%) грешке у Табели 4.

На основу резултата предикције 22 фотоакустичка сигнала приказаних у Табели 4, јасно се види да мрежа врши изузетно прецизну предикцију која има грешке у односу на параметре задатих сигнала мања од 1%. Као пример смо одабрали пет фотоакустичких сигнала формираних предикцијом мреже из Табеле 3 и представили их на слици 33.

Табела 3. Тест и предикција 22 фотоакустичка сигнала неуронском мрежом ANN1

Задати параметри			Предикција мреже		
D_T	α_T	l	D_T^{ANN}	α_T^{ANN}	l^{ANN}
$[10^{-5} \text{m}^2 \text{s}^{-1}]$	$[10^{-6} \text{K}^{-1}]$	$[10^2 \mu\text{m}]$	$[10^{-5} \text{m}^2 \text{s}^{-1}]$	$[10^{-6} \text{K}^{-1}]$	$[10^2 \mu\text{m}]$
9	2,6	9,35	8,9999	2,5998	9,3500
9	2,6	4,12	9,0001	2,5998	4,1199
9	2,6	1,8	8,9902	2,6053	1,8011
9,7	2,6	7	9,7003	2,5998	7,0001
8,943	2,6	7	8,9427	2,5999	6,9999
8,156	2,6	7	8,1560	2,5999	7,0001
9	2,74	7	9,0001	2,7397	6,9999
9	3	7	9,0001	2,7998	7,0000
9	2,5172	7	9,0000	2,5171	6,9999
9	2,3455	7	8,9998	2,3454	6,9999
9	2,75	8,81	8,9999	2,7503	8,8100
9	2,3605	1,25	9,0061	2,3575	1,2494
9	2,4588	6,25	8,9999	2,4589	6,2500
9,387	2,6	7,33	9,3869	2,5999	7,3299
8,299	2,6	2,6	8,2981	2,6004	2,6000
9,852	2,6	9,2	9,8520	2,5999	9,1999
9,601	2,5433	7	9,6008	2,5435	7,0000
8,119	2,8387	7	8,1192	2,8388	7,0001
9,18	2,4866	7	9,1797	2,4871	7,0001
8,895	2,672	1,69	8,8957	2,6721	1,6899
8,6	2,415	5,79	8,6000	2,4147	5,7899
8,33	2,616	7,21	8,3300	2,6159	7,2100



Слика 33. Пример 5 фотоакустичких сигнала, амплитуде и б) фазе, са којима је тестирана неуронска мрежа, силицијума n-типа које нису у кораку обуке неуронске мреже.

Табела 4. Максимална (%) и средња (%) грешка за D_T , α_T и l , за 22 тест ФА сигнала.

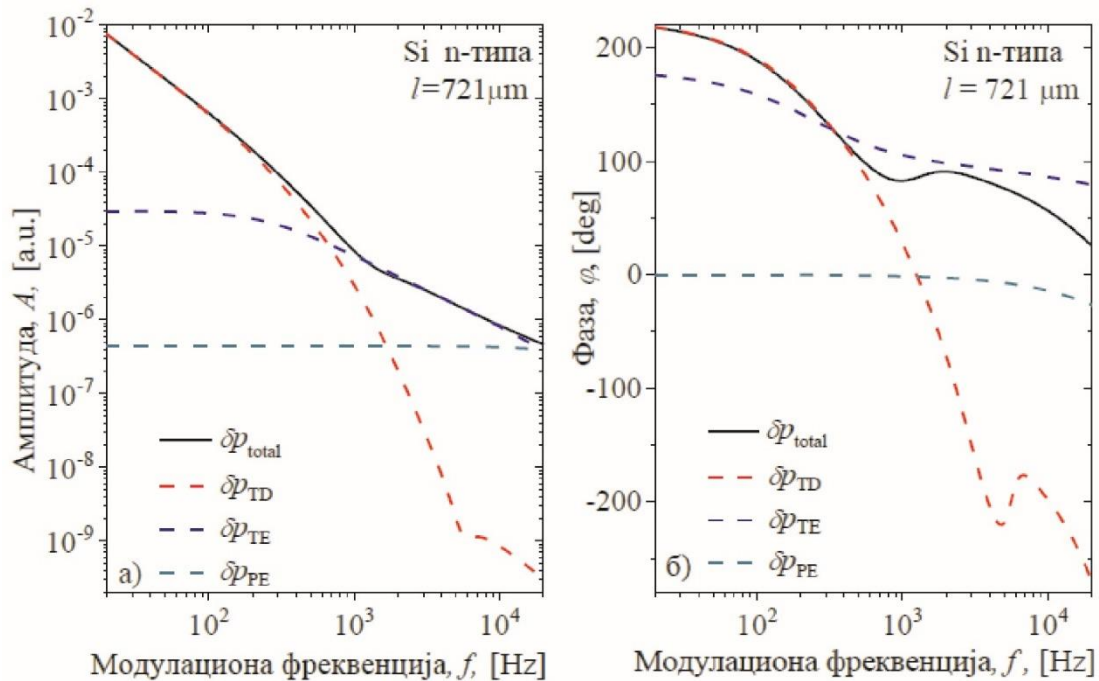
	$D_T [10^{-5} \text{ m}^2 \text{ s}^{-1}]$	$\alpha_T [10^{-6} \text{ K}^{-1}]$	$l [10^{-4} \text{ m}]$
Макс. грешка(%)	0.6128	0.5298	0.1090
Средња грешка(%)	0.0178	0.8254	0.0025

Овом анализом са фотоакустичким сигнаlima који су одређени параметрима ван корака промене базе, али су ипак у опсегу промене параметра од $\pm 10\%$, показано је да неуронска мрежа показује изузетну прецизност и на другачије формираним подацима. Показано је, такође да је време предикције остало исто $7.1 \mu\text{s}$.

4.1.6. *Анализа термоеластичних и плазмаеластичних процеса у полупроводнику*

Велика прецизност термоеластичних и геометријских својстава полупроводника одређених применом неуронских мрежа може да се искористи за додатну анализу ефеката који су довели до специфичног понашања фотоакустичких сигнала у фреквентном домену. Заменом параметара у теоријски модел одређују се области доминације поменутих ефеката.

Повратком параметара узорка добијених предикцијом мреже (Табела 3) у теоријски модел (поглавље 2.3) могуће је да се, поред потврде облика фотоакустичког сигнала у фреквентном домену, одреде и појединачне компоненте укупног фотоакустичког сигнала: термодифузиона, термоеластична и плазмаеластична. То можемо урадити употребом једначина (37), (47) и (48). Крајњи резултат за узорак дебљине нпр. $721 \mu\text{m}$ приказан је на слици 34, где су поред фреквентне зависности укупног сигнала приказане и појединачне компоненте [44,48]. Даљом анализом слике 34 се уочава доминација појединачних ефеката у фреквентном домену. Може се уочити велики утицај термодифузионог ефеката на нижим фреквенцијама $f < 10^3 \text{ Hz}$, док је на вишим фреквенцијама $f > 10 \text{ kHz}$ преовлађујући утицај термоеластичног ефеката (термоеластична компонента доминира у укупном сигналу). Плазма еластични ефекти почињу да утичу на сигнал тек при $f > 10 \text{ kHz}$. Ово су типичне фреквентне области појава поменутих ефеката код плазма-дебелих узорак [103,104].



Слика 34. ФА сигнал добијен параметрима из предикције НМ који се састоји од а) амплитуде и б) фазе укупног ФА сигнала и његове компоненте за узорак дебљине 721 μm силицијум n-типа из Табеле 5.

Важно је напоменути да неуронске мреже обучене на начин приказан у овој глави не могу врши прецизну предикцију ван тог опсега промене параметара, тј. не могу се користити за екстраполацију.

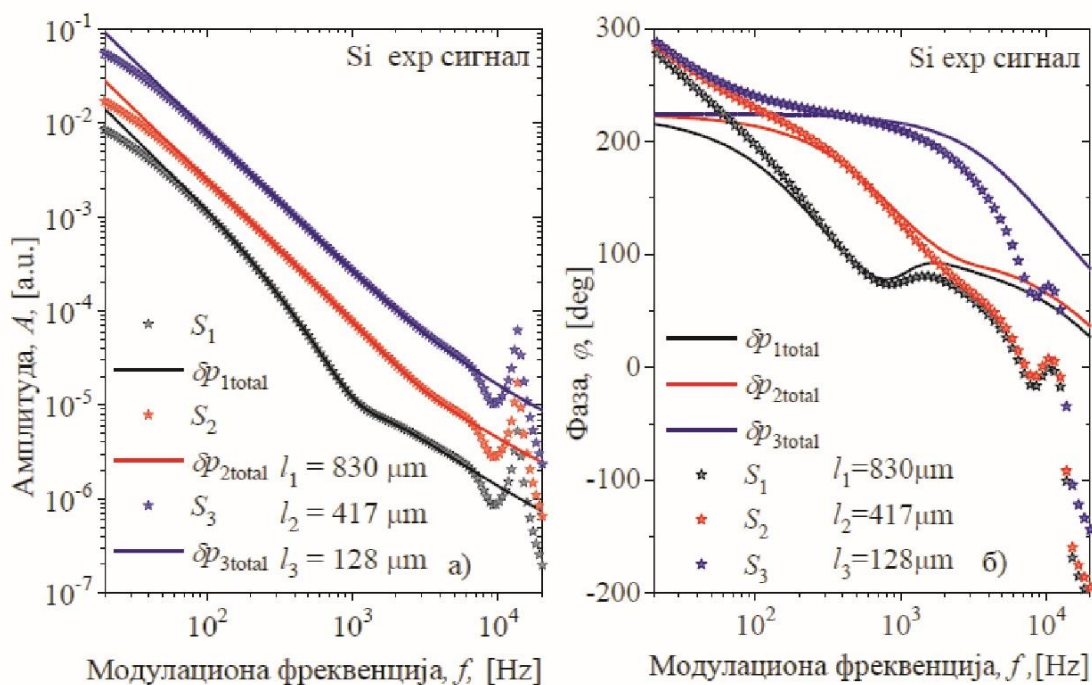
4.2. Карактеризација експерименталних узорака – предикција параметара

У раду са обученом неуронском мрежом у предикцији параметара узорака запажено је да мрежа није у стању да препозна криве из датог опсега фреквенција са другачијим кораком од оног представљеног мрежи током обуке. Другим речима, неуронске мреже не могу да интерполирају улазне параметре. То јесте велики проблем јер поставља унапред дефинисан захтев да се у експерименту или држимо задатих фреквенци обуке неуронске мреже, или да након прикупљања експерименталних података фитујемо податке на тај начин да крива фита садржи тражене вредности фреквенција које су мрежи представљене као улаз током тренинга. У поглављу 3.3.1 је наведено да је најједноставније решење неуронске мреже обучавати на фреквенцијама мерења експерименталних сигнала. То нас је довело до одлуке да у улазном слоју неуронске мреже имамо онолико неурона колико има фреквенција у експерименталном мерењу. Тако због 72 фреквенције које се обично користе

у нашем експерименту, за мрежу ANN1 (амплитуде и фазе) имамо 144 улазних неурона, и за мреже ANN2 (амплитуде) и ANN3 (фазе) 72 улазна неурона.


Практична примена све три обучене неуронске мреже је урађена на фотоакустичким сигнаlima добијеним експерименталним мерењима отвореном фотоакустичком ћелијом (поглавље 2.3.1) чији фреквентни корак прати обука неуронске мреже. Измерени су експериментални сигнали $S(f)$ за три узорка силицијума осветљаваних модулисаном светлошћу таласне дужине 660nm, у опсегу промене модулационе фреквенције од 20Hz до 20kHz. Узорци су били облика кружне плочице полупречника $R_s=4\text{mm}$, и дебљина l које имају вредности 830 μm , 417 μm и 128 μm , са вредностима параметара дифузивности $D_T = 9.0 \times 10^{-5} \text{m}^2 \text{s}^{-1}$ и термалне експанзије $\alpha_T = 2.6 \cdot 10^{-6} \text{K}^{-1}$ [16].

Поред тога што се у експериментима мора водити рачуна да се модулационе фреквенције мерења поклапају са фреквенцијама на којима је мрежа обучавана, велики проблем могу представљати инструменталне сметње. Због постојања сметњи које у експериментима утичу у читавој области фреквенција модулације неопходно је, пре представљања сигнала неуронској мрежи, извршити корекцију његових амплитуда и фаза методама описаним у поглављу 2.4. Само тако коригован сигнал има смисла представити мрежи и она ће онда сигурно коректно извршити карактеризацију испитиваног узорка.



Слика 35. Фреквентна зависност: а) амплитуда и б) фаза експерименталних мерења фотоакустичких сигнала $S(f)$ (звездице) три узорка силицијума *n*-типа (дебљина $l_1=830\mu\text{m}$, $l_2=417\mu\text{m}$ и $l_3=128\mu\text{m}$) и одговарајућих амплитуда и фаза очишћених сигнала $\delta\mathcal{P}_{\text{total}}(f)$ (линија) добијених након уклањања инструменталних девијација.

Амплитуде A и фазе φ експериментално измереног фотоакустичког сигнала $S(f)$ (поглавље 2.2) у овом раду приказане су звездицама на слици 35, за све три дебљине узорка. Фитовањем $S(f)$ (једначина (52)) се може одредити утицај мерног система $H(f)$ (једначине (53) и (54)). „Прави“ фотоакустички сигнал $\delta p_{\text{total}}(f)$ (пуне линије на слици 35) који потиче од самог узорка, добија се дељењем $S(f)$ са $H(f)$ [31-35]. Добијени $\delta p_{\text{total}}(f)$, тзв. кориговани сигнал, одговара тачно одређеним вредностима параметара дифузивности D_T и експанзије α_T [105,106]. Амплитуде $A_n(f)$ и фазе $\varphi_{\text{total}}(f)$ овако добијених $\delta p_{\text{total}}(f)$ за све дебљине узорка (слика 36) су претстављене неуронској мрежи, уз претходну нормализацију амплитуде (поглавље 4.1.1).



Слика 36. Фотоакустички сигнал $\delta p_{\text{total}}(f)$ а) нормализована вредност амплитуде $A_{\text{total}}(f)$ и б) вредност фазе $\varphi_{\text{total}}(f)$ добијених за три различите дебљине узорка l које су дате неуронским мрежама за предикцију.

У предикцији овако очишћених експерименталних фотоакустичких сигнала, користили смо поново три мреже, ANN1, ANN2 и ANN3 (поглавље 4.1.3, и 4.1.5), које су трениране са амплитудама и фазама (ANN1), само на амплитудама (ANN2) и само на фазама (ANN3) [48]. Њихове предикције за фотоакустичке сигнале приказане на слици 36 означили смо са D_T^{ANN} , α_T^{ANN} и l^{ANN} и приказали у Табели 5. Одступања, односно апсолутне (Ап Гр) и релативне (%) грешке које су мреже направиле, одређене су у односу на параметре узорка силицијума D_T , α_T и l добијених раније [16].

На основу резултата у Табели 5 види се да је у предикцији експерименталних резултата најпрецизнија мрежа ANN1 са грешкама мањим од 1%, док мреже ANN2 и ANN3 имају веће грешке нарочито на тањем узорку. Један од закључака на основу резултата Табеле 5 је потврда претпоставке да су експериментални фотоакустички сигнали плазма-дебелих узорака ($l > L$, поглавље 3.2) погодни за анализу неуронским мрежама. Код узорака код којих је $l \gg L$ предикције све три мреже су доста прецизне. Код узорака који се приближавају граници за плазма-танке узорке ($l \rightarrow L$) мреже ANN2 и ANN3 више греше, нарочито у предикцији параметра термалне дифузивности.

Табела 5. Параметри D_T^{ANN} , α_T^{ANN} и l^{ANN} добијени предикцијом различитих неуронских мрежа ANN1, ANN2 и ANN3. Апсолутне грешке које представљају разлику параметра добијених предикцијом и параметара D_T , α_T и l добијених стандарним ФА техникама. Релативне % грешке прорачунате према параметрима стандардних техника.

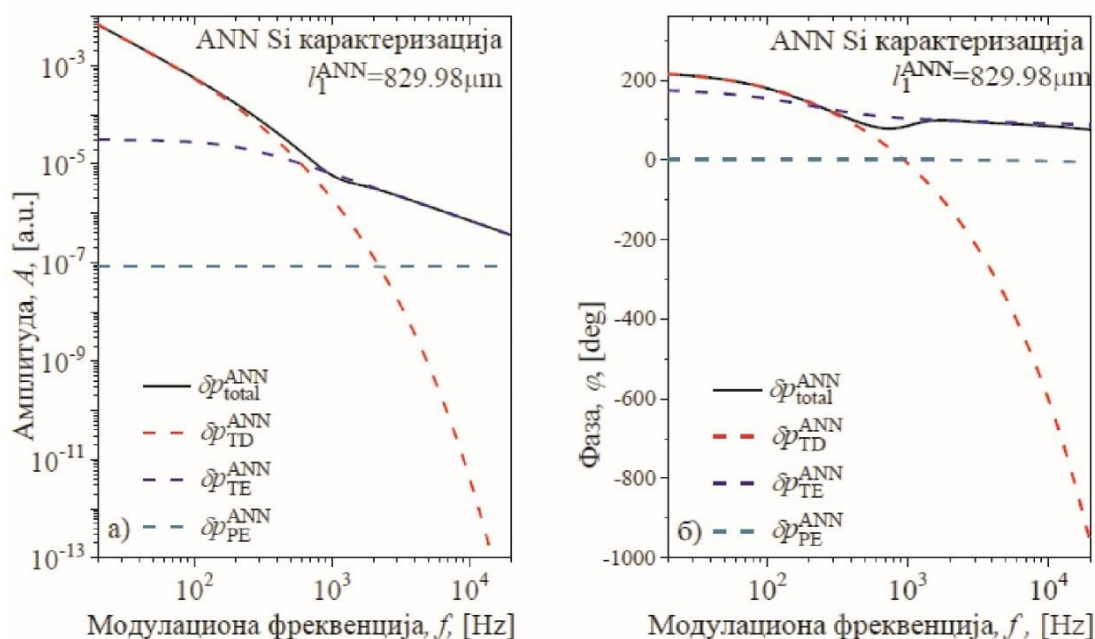
	Узорак бр.1 (830 μm)			Узорак бр.2 (417 μm)			Узорак бр. 3 (128 μm)		
параметри	D_T^{ANN}	α_T^{ANN}	l^{ANN}	D_T^{ANN}	α_T^{ANN}	l^{ANN}	D_T^{ANN}	α_T^{ANN}	l^{ANN}
јединице	$[10^{-5}\text{m}^2\text{s}^{-1}]$	$[10^{-6}\text{K}^{-1}]$	$[10^2\mu\text{m}]$	$[10^{-5}\text{m}^2\text{s}^{-1}]$	$[10^{-6}\text{K}^{-1}]$	$[10^2\mu\text{m}]$	$[10^{-5}\text{m}^2\text{s}^{-1}]$	$[10^{-6}\text{K}^{-1}]$	$[10^2\mu\text{m}]$
ANN1	9.0030	2.5995	8.2998	8.9994	2.5993	4.1687	9.0093	2.5952	1.2802
Ап Гр	0.0030	0.0005	0.0002	0.0006	0.0007	0.0013	0.0093	0.0048	0.0002
Рел гр %	0.0333	0.0192	0.0024	0.0067	0.0269	0.0312	0.1033	0.1846	0.0156
ANN2	9.0048	2.5591	8.2991	9.0123	2.6016	4.1728	9.8222	2.5042	1.4132
Грешке	0.0048	0.0009	0.0009	0.0123	0.0016	0.0028	0.8222	0.0958	0.1332
Рел гр %	0.0533	0.0346	0.0108	0.1367	0.0615	0.0671	9.1356	3.6846	10.4062
ANN3	9.0014	2.5994	8.2990	8.9965	2.6040	4.1691	11.6601	2.2463	1.4599
Грешке	0.0014	0.0006	0.0010	0.0035	0.0040	0.0009	2.6601	0.3537	0.1799
Рел гр %	0.0156	0.0231	0.0120	0.0389	0.1538	0.0216	29.5567	13.6038	14.0547

Резултати Табеле 5 поново указују да је генерално најбољи избор у предикцији фотоакустичких сигнала мрежа ANN1 (амплитуде и фазе) [48]. Своју поузданост и прецизност у предикцији сва три параметра D_T^{ANN} , α_T^{ANN} и l^{ANN} , мрежа ANN1 је показала укупно на три теста: тесту независних сигнала (Табела 2), тесту сигнала ван корака промене (Табеле 3 и 4), и сада на тесту експерименталних фотоакустичких сигнала (Табела 5).

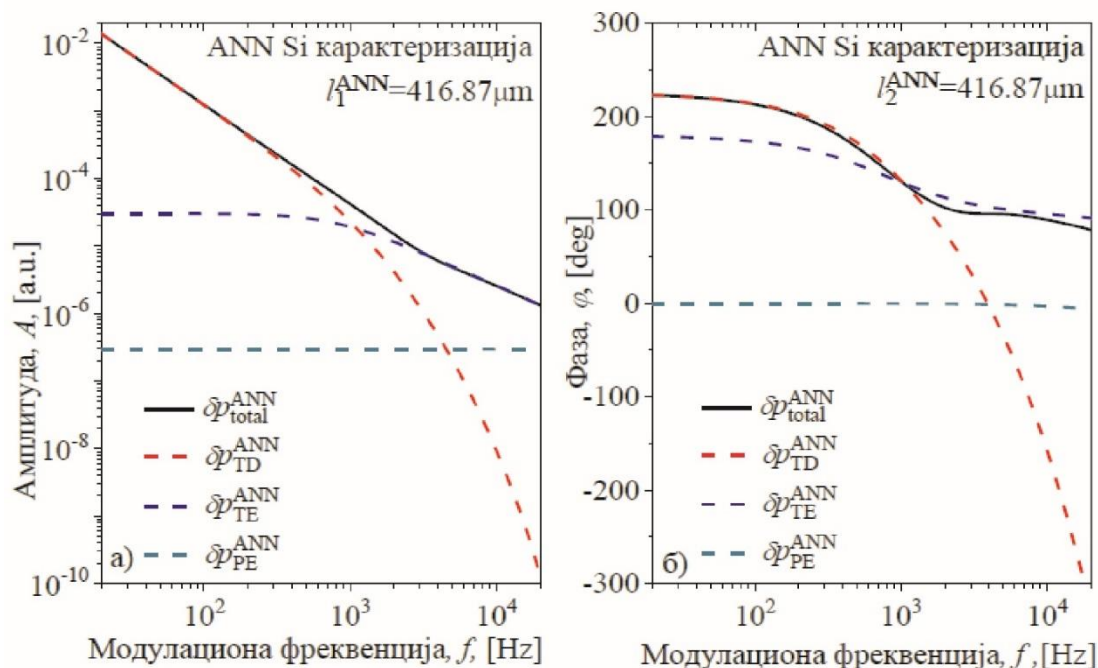
4.3. Решавање инверзног проблема и анализа термоеластичних процеса.

Употребом предикције мреже D_T^{ANN} , α_T^{ANN} и l^{ANN} (Табела 5) и теоријског модела (поглавље 2.3, једначина (49)) одређују се, осим укупне компоненте фотоакустичког сигнала $\delta p_{\text{total}}^{\text{ANN}}(f)$, и компоненте термодифузије $\delta p_{\text{TD}}^{\text{ANN}}(f)$ (једначина (37)), термоеластична компонента $\delta p_{\text{TE}}^{\text{ANN}}(f)$ (једначина (47)) и плазмаеластична компонента


$\delta p_{PE}^{ANN}(f)$ (једначина (48)). На овај начин добијени су фотоакустички сигнали и њихове компоненте (слике 36-38) за сва три анализирана узорка дебљине 830 μm , 417 μm и 128 μm .



Слика 37. Фреквентна карактеризација укупног фотоакустичког сигнала силицијумског узорка n-типа са компонентама термодифузионом, термоеластичном и плазмаеластичном за параметаре узорка дебљине $l_1^{ANN} = 829.98\mu\text{m}$, $D_T^{ANN} = 9.0030 \times 10^{-5} \text{m}^2 \text{s}^{-1}$ и $\alpha_T^{ANN} = 2.5995 \times 10^{-6} \text{K}^{-1}$ добијених предикцијом неуронске мреже.



Слика 38. Приказ фреквентне зависности тотоалног фотоакустичког сигнала и три његове компоненте за узорак силицијума за вредности параметара предикције неуронске мреже $l_2^{ANN} = 416.87\mu\text{m}$, $D_T^{ANN} = 8.9994 \times 10^{-5} \text{m}^2 \text{s}^{-1}$ и $\alpha_T^{ANN} = 2.5993 \times 10^{-6} \text{K}^{-1}$.



Слика 39. Катактеризација узорка силицијума у фреквентном домену, након предикције параметара неуронском мрежом $l_3^{\text{ANN}}=128.02\mu\text{m}$, $D_T^{\text{ANN}}=9.0093\times 10^{-5}\text{m}^2\text{s}^{-1}$ и $\alpha_T^{\text{ANN}}=2.5952\times 10^{-6}\text{K}^{-1}$. Катактеризација је дата фотоакустичким сигналом са термодифузионом, термоеластичном и плазмаеластичном компонентом.

Помоћу слика 37, 38 и 39, могу се анализирати утицаји многих ефеката, и њихове међусобне зависности, на стварање звука. То је суштина инверзног проблема у фотоакустици. На слици 37 је јасно да ефекти термалне дифузије (ефекти топлотног клипа – црвена испрекидана линија) доминирају у нискофреквентној области, ($f < 10^3$ Hz), тј. у тој области $\delta p_{\text{TD}}^{\text{ANN}}(f)$ компонента доминира у $\delta p_{\text{total}}^{\text{ANN}}(f)$. Компонента $\delta p_{\text{TD}}^{\text{ANN}}(f)$ даје информацију о топлотној дифузивности у узорку, дозвољавајући да се одреде и остали параметри везани за њу: густина узорка, специфична топлота и топлотна проводљивост. Смањењем дебљине (слике 38 и 39), доминација $\delta p_{\text{TD}}^{\text{ANN}}(f)$ компоненте постаје очигледна у много ширем фреквентном домену. У високофреквентној области (слика 39, $f > 10^3$ Hz), доминирају термоеластични ефекти (ефекти механичког клипа – плава испрекидана линија), јер у тој области $\delta p_{\text{TE}}^{\text{ANN}}(f)$ компонента доминира у $\delta p_{\text{total}}^{\text{ANN}}(f)$. Компонента $\delta p_{\text{TE}}^{\text{ANN}}(f)$ даје информације о температурном ширењу узорка, температурним разликама предње и задње површине узорка, и његовим геометријским параметрима. Под одређеним условима добијају се и неки еластични параметри материјала (Yung modulus на пример). Повећањем дебљине (слике 38 и 37) доминација $\delta p_{\text{TE}}^{\text{ANN}}(f)$ компоненте постаје очигледна у много ширем фреквентном домену. То значи да у су дебљи узорци погоднији за одређивање термоеластичних параметара. На свим поменутих сликама утицај

плазмаеластичног ефекта тј. $\delta p_{PE}^{ANN}(f)$ компоненте на $\delta p_{total}^{ANN}(f)$, је мали и практично занемарљив.

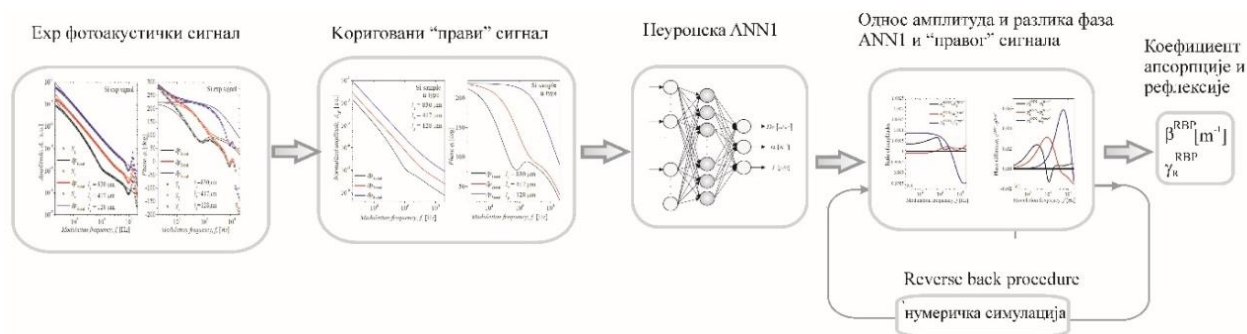
На описан начин, предикцијом параметара узорка помоћу неуронских мрежа одређени су фреквентни облици зависности $\delta p_{total}^{ANN}(f)$ и свих његових компоненти $\delta p_{TD}^{ANN}(f)$, $\delta p_{TE}^{ANN}(f)$ и $\delta p_{PE}^{ANN}(f)$ плочица силицијума n-типа побуђених модулисаним светлосним извором у фреквентном домену 20Hz–20kHz. Уочена је доминација појединих ефеката у различитим опсезима фреквенције, што отвара могућност одређивања већег броја својстава полупроводника и побољшања теоријског модела. тј. решен је инверзни проблем фотоакустике.

4.4. Контрола стабилности експеримента неуронским мрежама анализом оптичких карактеристика узорка

У претходним поглављима утврђено је да је добро обучена неуронска мрежа (ANN1) изузетно прецизна и поуздана у предикцији карактеристичних параметара узорка. То нам даје за право да претпоставимо да све разлике између D_T^{ANN} , α_T^{ANN} и l^{ANN} и D_T , α_T и l припишемо неком ефекту или сметњи која се јавља у експерименту. Два ефекта везана за оптичке карактеристике узорка се издвајају као главни кандидати за ову анализу. Први је ефекат мале промене (нпр. 1.5%) таласне дужине λ извора зрачења који јако мења (~9%) апсорциони коефицијент β силицијума. Други ефекат је промена стања површина узорака због различитих врста нечистоћа, при чему се мења коефицијент рефлексије γ_R силицијума.

Анализирањем једначина (13) и (29) може се уочити да, у фреквентном домену, концентрација $\delta n_p(x, f)$ и температура $T_s(x, f)$ утичу на понашање укупног фотоакустичког одзива $\delta p_{total}(f)$ (једначина (49)), и да у њима постоји изражена зависност од коефицијента апсорпције β и рефлексије γ_R . То даје могућност да се, на основу поређења фотоакустичког одзива предикције мреже (нпр. слике 37-39) са одзивом на основу литературних вредности, повратним поступком (reverse-back procedure) одређују β и γ_R , мењајући их све док се поменути одзиви не поклопе са (слика 36). Таква процедура престравља моћан алат за праћење и проверу поузданости употребљених инструмената и за проверу стања површина испитаног узорка. Вредности β^{RBP} и γ_R^{RBP} , које одговарају поклапању ових одзива, служе за израчунавање промене таласне дужине извора зрачења и

степену задржанosti површина узорка. Једноставна схема описаног повратног поступка приказана је на слици 40.




Слика 40. Процедура повратка уназад фотоакустичког сигнала одређеног предикцијом неуронске мреже до „правог“ експерименталног ФА одзива силицијумских узорака n-типа за одређивање коефициента апсорпције β^{RBP} и рефлексије γ_R^{RBP} .

У примерима из претходног поглавља установљено је да, иако мала (Табела 5, <0,2%), постоји разлика између „правих“ фотоакустичких сигнала (слика 36) и сигнала ANN мрежне предикције коју ћемо, једноставности ради, означити са ANN (слика 37). Да би се разлика између ова два фотоакустичка сигнала јасно видела израчунати су односи амплитуда $A^{ANN} / A^{„прави“}$ и разлике фаза $\varphi^{ANN} - \varphi^{„прави“}$ и представљени на слици 41, за сва три узорка.

Пошто нам је мрежа ANN1 веома прецизна и поуздана, одступања која су приказана на слици 41 могу се приписати промени експерименталних услова, и то а) промени таласне дужине коју приписујемо промени коефициента апсорпције узорка и б) стању и квалитету површине која мења коефициент рефлексије.

За „праве“ фотоакустичке сигнале (слика 36) претпостављено је да су добијени осветљавањем узорка светлошћу таласне дужине 660nm, којој одговара коефициент апсорпције $\beta = 2.6 \times 10^5 \text{ m}^{-1}$. За чисте површине узорка претпостављено је да подразумеван је коефициент рефлексије $\gamma_R = 0.35$. За ANN сигнале добијене предикцијом (слике 37-39), међане су вредности β и γ_R све док односи амплитуда не постану једнаки јединици, а разлике фаза нули. Тако се добијају β^{RBP} и γ_R^{RBP} . Резултати овако изведене повратне процедуре (reverse-back procedure-RBP) дати су у Табели 6. Релативна грешка (%) одређивања коефициента апсорпције и рефлексије је одређена разликом добијених β^{RBP} и γ_R^{RBP} и литерарних вредности $\beta = 2.6 \times 10^5 \text{ m}^{-1}$ и $\gamma_R = 0.35$.



Слика 41 а) однос амплитуда и б) разлика ФА сигнала предикције НМ и “правог” сигнала.

У Табели 6 су, такође, дате вредности апсорбанције $\beta^{RBP}l^{ANN}$ која се израчунава као производ вредности коефицијента апсорпције и рефлексије одређене овом процедуром. Апсорбанца, као контролни параметар, за сва три узорка има вредности $\beta^{RBP}l^{ANN} \gg 1$, што говори да је ефекат вишеструких рефлексија светлости унутар узорка занемарљив [10,108,109].


Табеле 6. Коефицијент апсорпције β^{RBP} и рефлективности γ_R^{RBP} добијених у повратном поступку (RBP) са одговарајућом (%) релативном грешком. Дата је вредност апсорбанце као производ коефицијента апсорпције и дебљине узорка $\beta^{RBP}l^{ANN}$.

	Узорак бр.1 (830 μ m)	Узорак бр.2 (417 μ m)	Узорак бр. 3 (128 μ m)
β^{RBP} [10^5 m^{-1}]	2.5785	2.5640	2.5940
Релативна грешка (%)	0.0581	0.6202	0.5424
γ_R^{RBP}	0.3450	0.3501	0.3510
Релативна грешка (%)	1.4286	0.0286	0.2857
$\beta^{RBP}l^{ANN}$	214.01	106.88	33.219

Најчешћи узрок флукуација зрачења ласерске диоде је радна температура, знајући да излазне карактеристике ласерске диоде (таласна дужина, ширина опсега ...) јако зависе од ње. Најчешћи узрок флукуације γ_R јесте природни оксидациони процес на Si површинама праћен стварањем ултра танког слоја SiO₂. Резултати у Табели 6 показују врло мале

флукуације вредности β и γ_R , што указује на то да ласерска диода исправно ради и да осветљене површине узорка нису контаминирани са SiO_2 .

На слици 42 приказане су нелинеарне корелације између коефициента апсорпције β^{RBP} добијеног у процедури повратка унатраг и параметара предикције мреже D_T^{ANN} , α_T^{ANN} и l^{ANN} . На основу добијених графика, чак и поред тога што је број тачака мали, разумно је закључити да је експериментална несигурност коефициента апсорпције (мала колебања таласне дужине ласерске диоде услед флукуација њене радне температуре) одговорана за случајну (некохерентну) расподелу вредности коефициента апсорпције β^{RBP} у Табели 6. Са друге стране, расподела вредности рефлексије γ_R^{RBP} у истој табели показује одређену кохерентност која указује да се процес оксидације на површини узорка може сматрати занемарљивим [49].



Слика 42. Корелација коефициента апсорпције β^{RBP} у зависности од дебљине l^{ANN} , дифузивности D_T^{ANN} и експанзије α^{ANN} добијених предикцијом ANN.

Резултати из Табеле 6 и са слике 42 показују да се метод повратне процедуре (RBP) може искористити како би се контролисали експериментални услови везани за нестабилности извора зрачења и/или контаминацију површине узорка. Ова метода се може искористити и у дизајнирању фотонских полуводничких уређаја, и може дати путоказ у ком смеру треба ићи и како исправити експерименталну поставку да би се постигле њене најбоље перформансе и добили поуздани параметри узорка у оквиру његове карактеризације.

4.5. Генерализација неуронске мреже

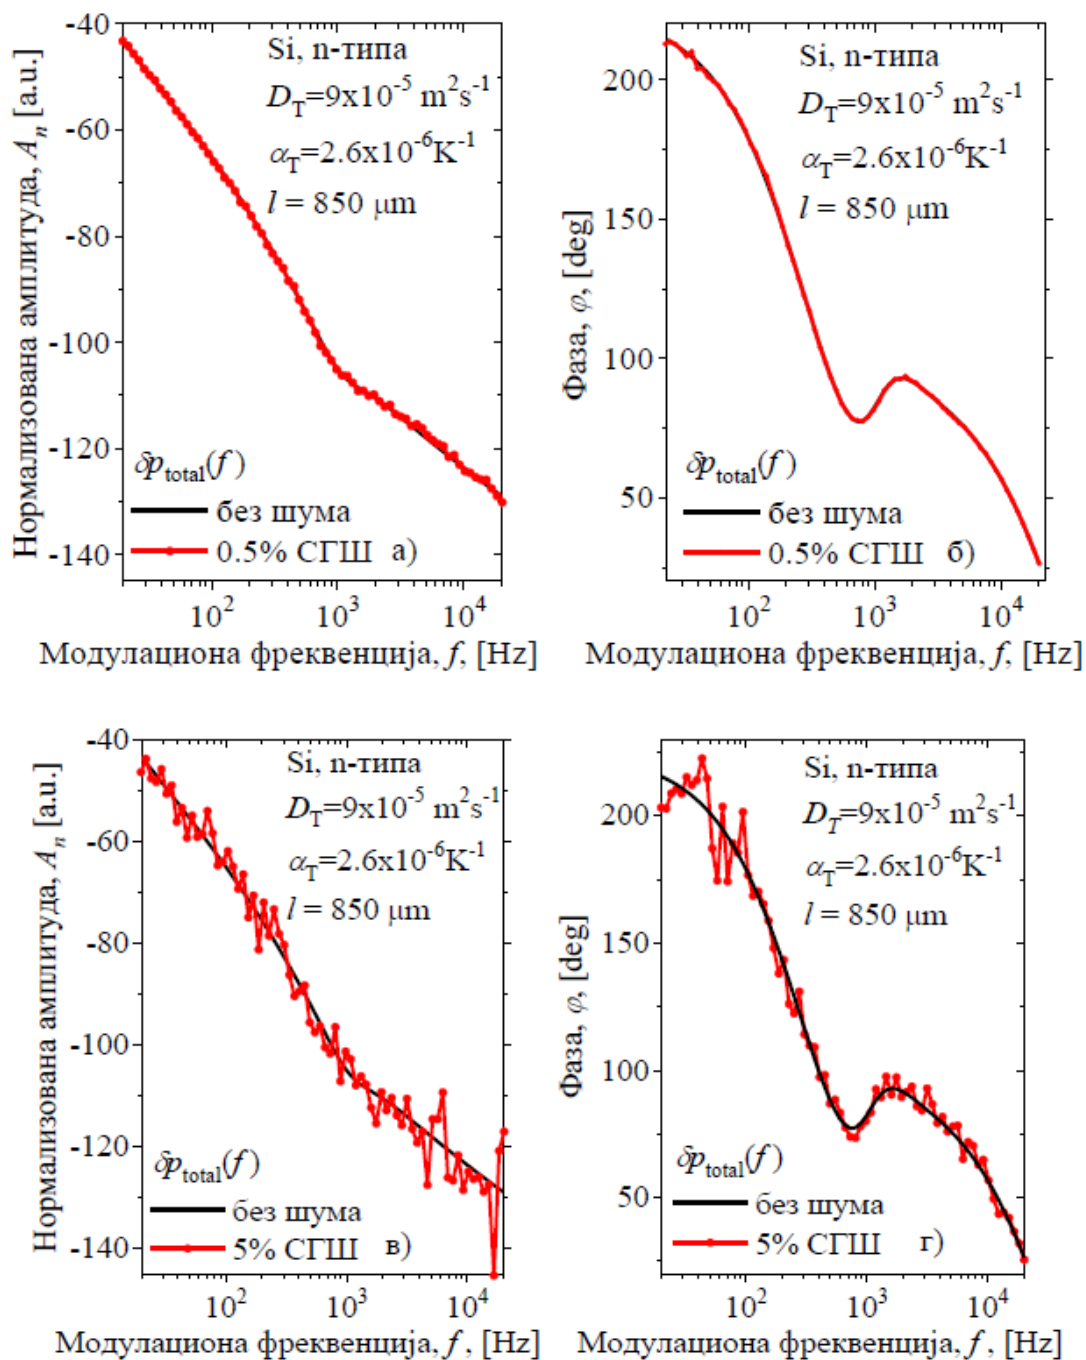
Увек када тренирамо неуронске мреже, морамо водити рачуна о нечему што се зове генерализација неуронске мреже. У нашем случају, под генерализацијом неуронске мреже подразумеваћемо прилагођавање обуке мреже реалним, експерименталним условима уз задржавање основне структуре мреже [104,110]. У овом поглављу дата је анализа промене укупних перформанси неуронске мреже које су обучаване на одабраној структури (поглавље 4.1.3, слика 21), обучавањем на истој бази са истим теоријским фотоакустичким сигнаlima, али са додатим различитим нивоима Гаусовог шума (Gauss noise) [111-115]. Анализом је одабран најповољнији ниво шума којим су задржане основне перформансе мреже (рад у реалном времену, поузданости и прецизности предикције излазних параметара) уз истовремено прилагођавање експерименталним условима и смањење времена њене обуке. Са друге стране потврђена је оправданост коришћења ANN у карактеризацији само плазма-дебелих узорака полупроводника, и то све кроз анализу како теоријских, тако и експерименталних података.

У претходним поглављима (4.1.1. и 4.1.5.) описано је како смо водили рачуна о томе да осигурамо добре перформансе мреже. Највећу пажњу смо обратили на то да се избегне претренираност мреже. Због тога смо и водили рачуна о структури саме мреже: редуковали смо број скривених слојева и неурона у њима на неопходан минимум у складу са карактеристикама улазних и излазних података које представљамо мрежи [113]. Међутим, и поред тога што смо у дизајнирању и тренирању мреже користили програм MathLab нисмо могли бити сигурни у потпуности да ли смо претренирали мрежу или не. Током обуке никада нисмо успели да активирамо механизам прекида тренинга заснован на одступању mse (једначина (74)) тренинга у односу на mse теста и валидације, ма колико епоха задали унапред.

Иако смо били свесни чињенице да превише епоха за тренирање може довести до прекомерног прилагођавања ANN улазним подацима што повлачи за собом велику грешку у предвиђањима, радили смо са неколико хиљада епоха и увек смо добијали добре перформансе мреже. То нас је навело на закључак да можда наша мрежа не може бити претренирана ако је обучавамо теоријским сигнаlima. Због тога смо одлучили да направимо тест и видимо да ли је наш закључак исправан или не. У ту сврху решили смо да, осим чисто теоријских кривих искористимо исте те криве али са различитим степеном додатог шума. Идеја је да са додатим шумом, осим што се прилагођавамо експерименталним условима, дозволимо мрежи да се „превише адаптира“ улазним

подацима, и тако покушамо да је уведемо у претренираност. То је урађено на свим већ коришћеним кривама из базе са слике 25 (поглавље 4.1.1.). Типичан пример једног таквог сигнала који је представљен мрежи дат је на слици 2 (црна линија) заједно са истим тим сигналимa али са додатим шумом (црвене линије) различитог нивоа: а и б) 0.5%, в и г) 5%.

Шум није додаван сигналимa само да би испитали поузданост тренинга и избегли сумњу у постојање претренираности мреже, већ и због претпоставке да би додавањем шума смањили време обуке мреже не губећи много на мрежним перформансама.

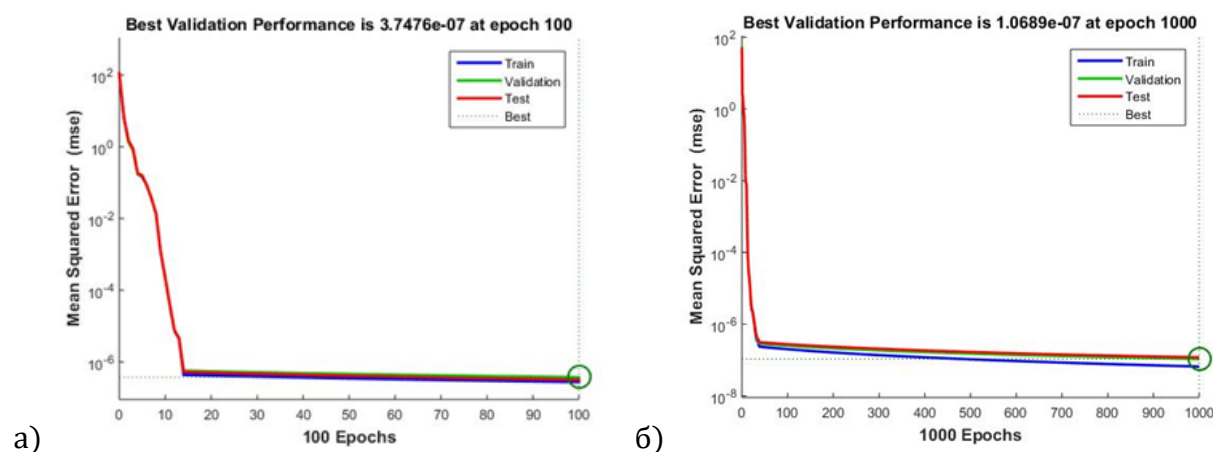


Слика 43. Симулација фотоакустичког одзива (црна линија), и сигнал истог одзива са а и б) 0.5% и в и г) 5% Гаусовог случајног шума (црвена линија).

Поред независног теста, коришћен је и тест са 22 ФА сигнала датих у Табели 3 (поглавље 4.1.5.) у истом опсегу измена параметара, али ван корака генерисања сигнала. На крају је поступак поновљен са три експериментално добијена сигнала (слика 36, поглавље 4.2.) како би се проверио и рад мреже на реалним подацима.

4.5.1. Обука без шума

Резултати тренинга мреже на сигналима без шума приказани су на слици 46. Тренинзи су рађени са произвољним избором броја епоха, од неколико стотина до неколико хиљада. На слици су дати примери обуке мреже са 100 и 1000 епоха. Још једном треба поменути да ни у једном случају тренинг није прекидан на основу задатог критеријума спречавања претренираности, већ само на основу броја задатих епоха. То је у складу са нашем претпоставком да мрежа која се тренира са теоријским сигналима не може бити претренирана.

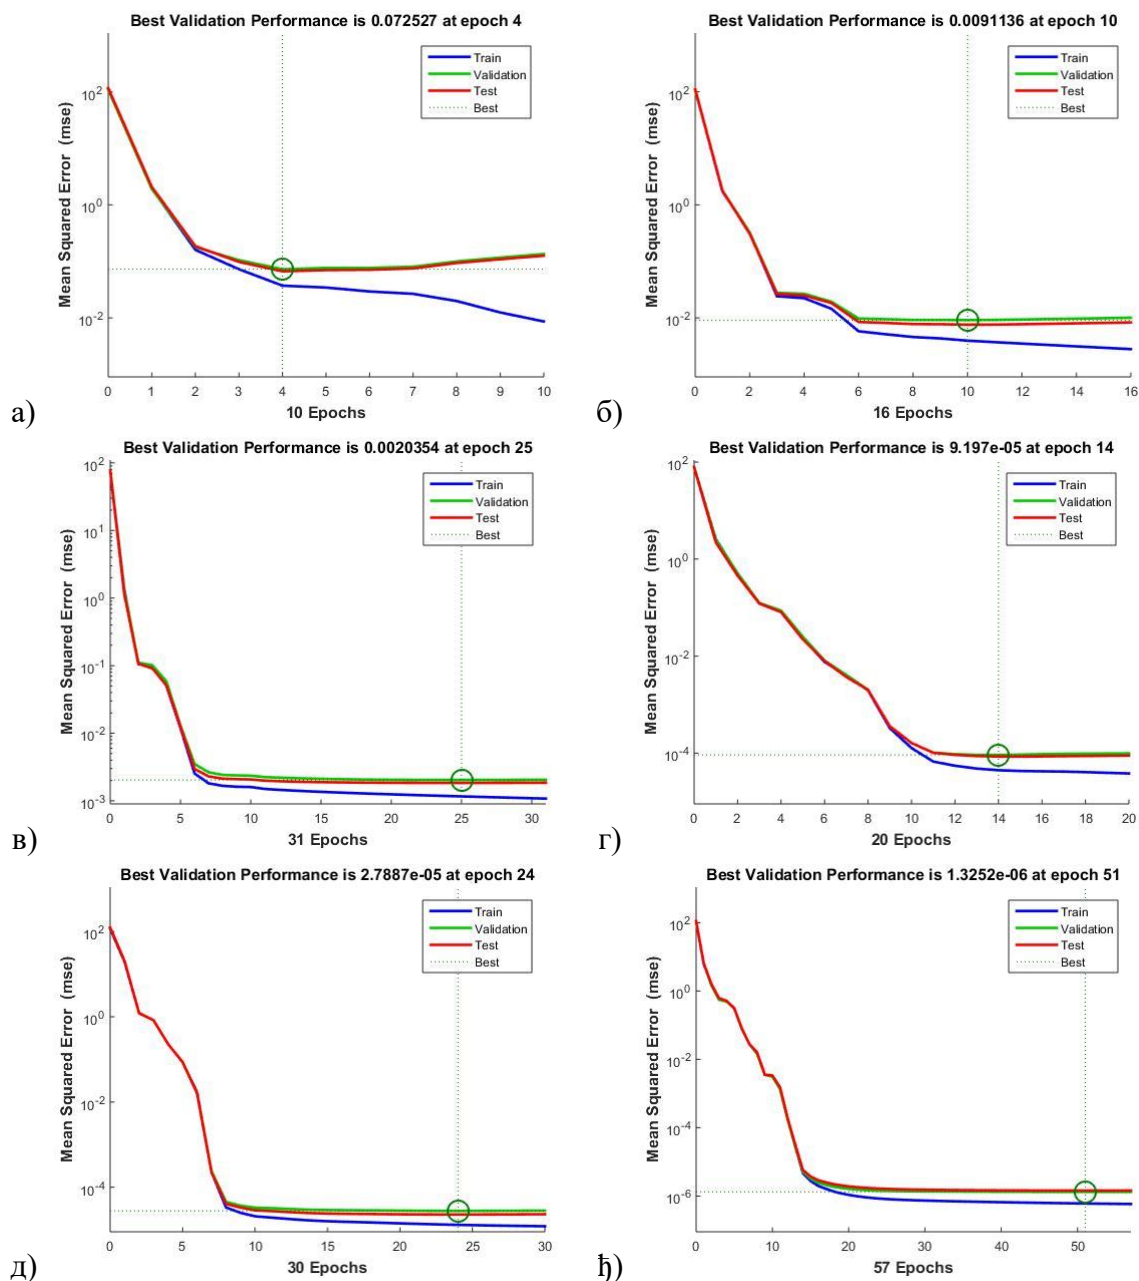


Слика 44. Средња квадратна грешка mse (једн. 74), за тренинг, валидација и тест неуронске мреже трениране у а) 100 и б) 1000 епоха.

4.5.2. Обука са шумом

За формирање неуронских мрежа са одређеним % шума коришћена је иста база података, тако да је на сваки ФА сигнал (улазни вектор), стављен случајни Гаусов шум различитим степеном, а) 5%, б) 1%, в) 0.5% г) 0.1% д) 0.05% и њ) 0.01%. Резултати перформанси тако обучаваних мрежа приказани су на слици 47 и у Табели 8, заједно са резултатима обуке чистим сигналима. Јасно се види да додавање Гаусовог шума мења динамику и карактеристике тренинга мреже. Изгледа да се подаци улазног вектора (ФА

сигнала) са већим % шума брже повежу (у мање епоха), али тако да тежине повезивања података нису довољно подешене (усклађене) са излазним вектором што се запажа у смањењу вредности перформансе (поузданости) тренинга повећањем шума.



Слика 45. Тренирање мреже са истом базом сигнала која има а) 5%, б) 1% в) 0.5% г) 0.1% д) 0.05% и њ) 0.01% Гаусовог случајног шума.


Тренинзи се заустављају након неколико десетина епоха, а што је већи % додатог шума, број епоха се значајно смањује – тренинг краће траје [113]. До заустављања тренинга за одређени број епоха долази у тренутку када се активира критеријум прекида тренинга дефинисаног помоћу mse (једначина (74)); линија тренинга (плава линија) почиње да се раздваја од линија валидације (зелена) и теста (црвена). Овакво понашање приликом

тренинга мреже указује на чињеницу да је додавање шума на теоријске сигнале добар начин да се провере перформансе мреже, а посебно да се искључи могућност њеног претренирања.

Табела 7. Перформансе и број епоха тренинга мрежа на ФА сигнаlima са одређеним % Гаусовог шума.

% СГШ	Бр епоха	Валидационе перформансе
5	4	0.072527
1	10	0.0091136
0.5	25	0.002035
0.1	14	0.00009197
0.05	24	0.000027887
0.01	51	0.0000013252

На слици 46 је дат приказ података тренинга мреже, број епоха и перформансе мрежа из Табеле 7, у зависности од одређеног % Гаусовог шума постављеног на излазне сигнале. Може се запазити да повећавањем процента шума, мрежа краће тренира (смањује број епоха) што доводи до бржег прекида тренинга.



Слика 46. Показује промену а) поузданости (performance) мрежа и б) број епоха обуке мрежа трениране на ФА сигнаlima Si n-типа, ако се на улазним сигнаlima постави у одређеном проценту случајни Гаусов шум.

4.5.3. Анализа предикције излазних података

На основу резултата приказаних у претходном параграфу (Табела 7 и слика 46) јасно је да перформансе мреже расту смањењем процентног удела шума у сигналу, и постају најбоље онда када шума нема. Та чињеница нам даје могућност да пронађемо оптималан однос између времена обуке мреже и њених задовољавајућих перформанси (перформансе добијене без шума су једна врста идеализације). Да би то урадили што коректније треба да анализирамо квалитет излазних података из мреже тј. колико прецизне резултате мрежа даје након обуке. У ту сврху смо мрежи представили 110 сигнала из базе којима мрежа није ни тренирана ни тестирана ни валидирана. Знајући да су излазни подаци мреже вредности D_T

, α_T и l испитиваног узорка, израчунате су грешке максималног (Макс грешка) и средњег (Средња грешка) одступања који појединачни параметри праве у предикцији у односу на њихове стварне вредности. Резултати су дати у Табели 8, на основу којих се види да највећу грешку има мрежа тренирана са највећим процентом шума (5% шума), и да грешке имају тенденцију смањивања са опадањем процентног удела Гаусовог шума. Најмању грешку има мрежа тренирана на чистим сигналимa и задовољавајуће малу мрежа обучавана са најмањим процентом шума (0.01%). Граница за оптималан ниво шума са којим је одступање у предикцији свих параметара испод 0.1% (Макс грешка и Средња грешка) износи 0.5% (испрекидана линија у Табели 8).

Табела 8. Максималне и средње грешке у предикцији параметра D_T , α_T и l чистог ФА сигнала (110ФАС) неуронским мрежама добијених додавањем различитог степена случајног Гаусовог шума од 0.01% до 5% на улазним подацима.

110ФАС % СГШ	Макс грешка			Средња грешка		
	D_T	α_T	l	D_T	α_T	l
0	0.0017	0.0005	0.0006	2E-5	2E-05	2E-06
0.01	0.0021	0.0009	0.0007	7E-05	5E-05	1E-05
0.05	0.0069	0.0017	0.0040	0.0006	3E-05	0.0003
0.1	0.0199	0.0040	0.0054	0.0009	0.0006	7E-06
0.5	0.0870	0.0242	0.0090	0.0043	0.0009	0.0034
1	0.1241	0.0402	0.0216	0.0174	0.0023	0.0041
5	0.7227	0.1920	0.2294	0.0606	0.0163	0.0552

Да би пронашли оптималан однос између времена обуке мреже и њених задовољавајућих перформанси погодна је искористити вредности релативних грешака предикције приказаних у Табели 9, имајући у виду чињеницу коју смо поменули раније, да су вредности параметара предикције нормализоване на тај начин да буду истог реда величине.

Табела 9. Максималне и средње релативне (%) грешке у предикцији параметра D_T , α_T и l чистих ФАС(110) сигнала у корацима обуке мреже, са мрежама добијених додавањем различитог степена случајног Гаусовог шума од 0.01% до 5% на улазним сигналимa.

110 ФАС % СГШ	Макс релативна грешка (%)			Средња релативна грешка (%)		
	D_T	α_T	l	D_T	α_T	l
0	0.0196	0.0188	0.0167	0.0035	0.0062	0.0029
0.01	0.0306	0.0352	0.0294	0.0079	0.0100	0.0052
0.05	0.0700	0.0659	0.1045	0.0189	0.0197	0.0151
0.1	0.2009	0.1521	0.3609	0.0330	0.0432	0.0478
0.5	0.8776	0.8480	0.9392	0.1468	0.2129	0.1274
1	1.3340	1.6426	1.7543	0.4093	0.4345	0.3013
5	8.3301	8.7607	13.975	2.8467	3.0178	2.1664

На основу резултата приказаних у Табели 9, граница за оптимални однос времена обуке мреже и задовољавајуће прецизности испод 1% (релативна грешка) предикције остварује се додавањем 0.5 % шума на теоријске сигнале.

4.5.4. Тест са сигналима ван корака промене параметара

Да би додатно проверили квалитет мрежних перформанси урадили смо тест са 22 ФА сигнала (Табела 3), који нису саставни део направљене базе (5491 сигнала) већ претстављају симулацију сигнала са кораком променом параметра који није исти као корак промене коришћен за формирање базе али свакако унутар задатог опсега промене параметара. Резултати ове анализе приказани су у Табели 4.

Табела 10. Максимална и средња грешка предикције параметара чистих фотоакустичких сигнала (22) који су ван корака обуке, неуронским мрежама са одрђеним % случајног Гаусовог шума постављеног на улазну базу

22 ФАС % СГШ	Макс грешка			Средња грешка		
	D_T	α_T	l	D_T	α_T	l
0	0.0098	0.0031	0.0006	0.0027	0.0003	0.0022
0.01	0.0207	0.0002	0.0055	5E-05	0.0003	4E-05
0.05	0.0241	0.0012	0.0397	0.0030	0.0014	0.0021
0.1	0.3627	0.0036	0.0651	0.0162	0.0003	0.0038
0.5	0.1914	0.0207	0.0113	0.0058	0.0012	0.0002
1	0.2900	0.0316	0.0102	0.0087	0.0028	0.0015
5	0.5101	0.1805	0.1665	0.0593	0.0232	0.0566

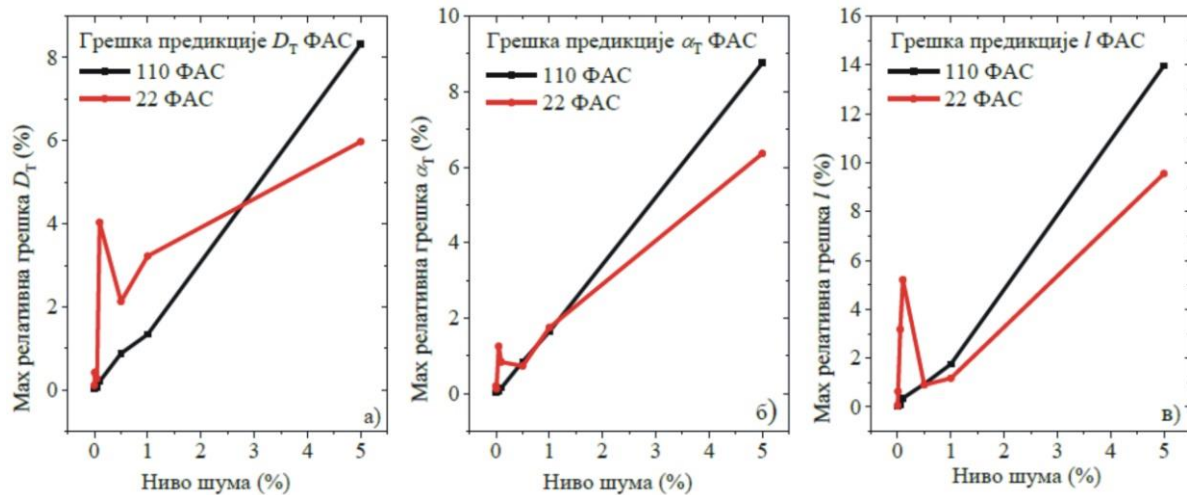
Добијени резултати јасно указују на то да постоји тенденција пораста грешака са порастом процента шума. Утрђено је да ФА сигнали који су ван корака промене параметара (22ФАС) имају веће грешке од сигнала теста (110ФАС), што је и очекивано. Највеће грешке неуронске мреже показују у предикцији параметра D_T . На основу приказаних резултата можемо закључити да правилно обучена ANN може прилично добро да остварује предикцију и на сигналима који су одабрани тако да им је корак промене свих параметара различит. Интересантно је приметити да најмању грешку процене параметара мрежа у оба случаја (110ФАС и 22ФАС) прави код коефицијента термалног ширења α_T . Граница за оптималан ниво шума са којим је одступање у предикцији свих параметара испод 0.1% (Макс грешка и Средња грешка) износи 0.05% (испрекидана линија у Табели 8).

Резултати максималне релативне грешке приказани су у Табели 9 и 11 и Слици 47, и указују на то да је најоптималнији однос времена обуке и прецизности предикције мреже добијен за 0.01 % шума. Максимална релативна грешка у процентима је израчуната на основу предикције у односу на задату вредност параметара. На основу резултата приказаних у Табели 11, граница за оптимални однос времена обуке мреже и

задовољавајуће прецизности испод 1% (релативна грешка) предикције остварује се додавањем 0.01 % шума на теоријске сигнале.

Табела 11. Максимална и средња релативна (%) грешка предикције три параметара: дифузивности, експанзије и дебљине узорака неуронским мрежама (тренираних са одређеним % случајног Гаусовог шума) на фотоакустичким сигнаlima који су ван корака обуке.

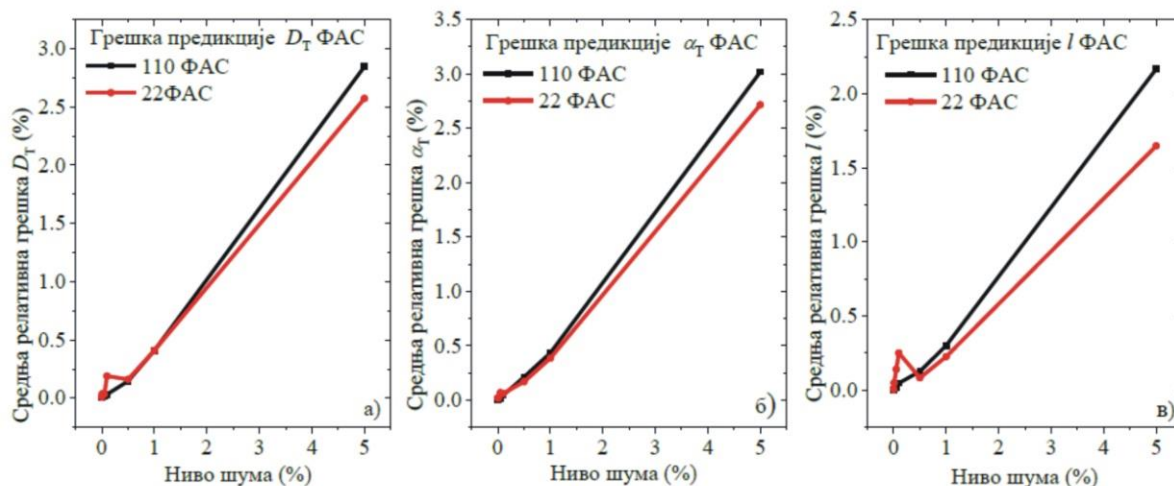
22 ФАС % СГШ	Макс релативна грешка (%)			Средња релативна грешка(%)		
	D_T	α_T	l	D_T	α_T	l
0	0.1088	0.2038	0.0605	0.0101	0.0214	0.0059
0.01	0.4178	0.1273	0.6337	0.0375	0.0147	0.0499
0.05	0.2714	1.2525	3.1768	0.0353	0.0685	0.1413
0.1	4.0305	0.8369	5.2051	0.1904	0.0594	0.2514
0.5	2.1263	0.7312	0.9007	0.1606	0.1693	0.0836
1	3.2219	1.7468	1.1787	0.4099	0.3850	0.2272
5	5.9761	6.3584	9.5493	2.5723	2.7165	1.6479



Слика 47. Максимална релативна грешка предикције три параметра а) дифузивности D_T , б) експанзије α_T и в) дебљине l узорака неуронским мрежама (тренираних на различитим % случајног Гаусовог шума) на ФАС у корацима промене параметара (110 ФАС-црна линија) и ван корака промене параметара (22 ФАС-црвена линија).

На слици 47 дат је приказ пораста максималних релативних грешака (%) предикције три параметара D_T , α_T и l датих на а), б) и в) неуронских мрежа из Табеле 9 и 11. Показује се да најбоље максималне релативне грешке показују мреже са додатих мање од 1% шума у односу на друге неуронске мреже.

Приказом средње релативне грешке (%), слика 48, за три параметра D_T , α_T и l предикције неуронских мрежа са различитим процентима шума, Табела 10 и 11 (испрекидана линија), потврђује се најбоље карактеристике мреже са мање од 1% шума.



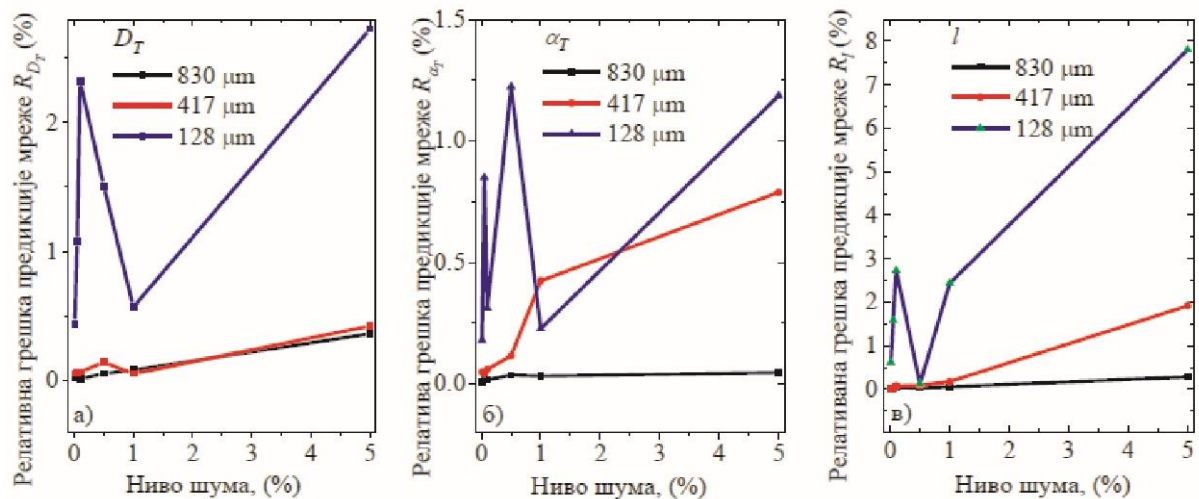
Слика 48. Приказ средњих релативних грешака (%), предикције параметара а) дифузивности D_T , б) експанзије α_T и в) дебљине узорка l неуронским мрежама са различитим нивоом шума за два теста: независног (110 ФАС – црна линија) и сигнала ван корака обуке мреже (22 ФАС – црвена линија).

4.5.5. Тест са експерименталним сигнаlima

У овом параграфу ћемо приказати предикцију неуронске мреже, обучавану са различитим процентима Гаусовог шума, урађену на експериментално измереним фотоакустичким сигнаlima добијеним коришћењем отворене ФА ћелије (поглавље 2.2), за три узорка Si n-типа дебљине $830\ \mu\text{m}$, $417\ \mu\text{m}$ и $128\ \mu\text{m}$ (слика 35 и 36). Резултати предикције мреже су дати у релативним грешкама и приказани су на слици 49 и у Табели 12.

Табела 12. Релативна (%) грешка предикције неуронских мрежа (са одређеним % Гаусовог шума) експерименталних резултата за три узорка (Табеле 5).

%СГШ	Узорак бр.1 (830 μm)			Узорак бр.2 (417 μm)			Узорак бр.3 (128 μm)		
	D_T	α_T	l	D_T	α_T	l	D_T	α_T	l
0.01%	0.0226	0.0070	0.0242	0.0548	0.0482	0.0129	0.4400	0.1788	0.6080
0.05%	0.0216	0.0228	0.0262	0.0593	0.0421	0.0059	1.0788	0.8496	1.5844
0.1%	0.0130	0.0155	0.0463	0.0662	0.0593	0.0741	2.3174	0.3104	2.7248
0.5%	0.0540	0.0356	0.0311	0.1429	0.1144	0.0881	1.5083	1.2238	0.1237
1%	0.0819	0.0311	0.0537	0.0528	0.4236	0.1747	0.5705	0.2266	2.4365
5%	0.3626	0.0458	0.2813	0.4225	0.7883	1.9146	2.7254	1.1860	7.8032



Слика 49. Релативне грешке (%) предикције при параметра а) термалне дифузивности D_T б) експанзије α_T и в) дебљине три узорка l , дебљине 830 μm (црна линија), 417 μm (црвена линија) и 128 μm (плава линија).

На основу добијених резултата јасно се види да за узорак дебљине 830 μm (црна линија, слика 49) није битно колики шум додајемо при обуци мреже тј. није битно коју мрежу користимо, јер су резултати релативне грешке предикције за сва три параметра узорка испод 1%. То већ није случај са узорком дебљине 417 μm код кога је исти услов задовољен за све мреже сем оне са 5% шума. Најмању прецизност предикције мреже добијамо за најтањи узорак дебљине 128 μm , што потврђује нашу претпоставку да ће се мрежа најбоље обучавати на дебљим узорцима.

Литература (Поглавље 4)

- [95] J. Sola, J. Sevilla, Importance of input data normalization for the application of neural networks to complex industrial problems, *IEEE Trans Nucl Sci*, 44 (3) 1464 - 1468 (1997) DOI: [10.1109/23.589532](https://doi.org/10.1109/23.589532)
- [96] S. Sumathi, T. Hamsapriya and P. Surekha, *Evolutionary Intelligence: An Introduction to Theory and Applications with Matlab* Verlag: Springer (2008) ISBN-13: [978-3540751588](https://www.isbn-international.org/product/978-3-540-75158-8)
- [97] S. Sumathi and P. Surekha, *Computational intelligence paradigms: theory & applications using MATLAB* Taylor & Francis Group: CRC Press (2010) ISBN [9781439809020](https://www.isbn-international.org/product/9781439809020) - CAT# [K10445](https://www.isbn-international.org/product/9781439809020)
- [98] D. Furundzic, M. Djordjevic A. J. Bekic, Neural networks approach to early breast cancer detection, *J SYST ARCHITECT*, 44, 8, 617-633 (1998) [https://doi.org/10.1016/S1383-7621\(97\)00067-2](https://doi.org/10.1016/S1383-7621(97)00067-2)
- [99] D. Furundzic, S. Stankovic, S. Jovicic, S. Punisic, M. Subotic, Distance based resampling of imbalanced classes: With an application example of speech quality assessment, *Eng. Appl. Artif. Intell*, 64, 440-461 (2017) <https://doi.org/10.1016/j.engappai.2017.07.001>
- [100] M. Lukić, Ž. Čojbašić, M. D. Rabasović, D. D. Markushev and D. M. Todorović, Neural Networks-Based Real-Time Determination of Laser Beam Spatial Profile and Vibrational-toTranslational relaxation Time Within Pulsed Photoacoustics, *Int. J. Thermophys.* 34 8–9 1795–1802 (2013) DOI: [10.1007/s10765-013-1507-y](https://doi.org/10.1007/s10765-013-1507-y)
- [101] Le Yi Wang, George Yin G, Zhao Y, Ji-Feng Zhang, Identification Input Design for Consistent Parameter Estimation of Linear Systems With Binary-Valued Output Observations, *IEEE T AUTOMAT CONTR* 53 (4) 867 - 880 (2008) DOI: [10.1109/TAC.2008.920222](https://doi.org/10.1109/TAC.2008.920222)
- [102] Z. N. Šoškić, S. Ćirić-Kostić, S. G. Galović, An extension to the methodology for characterization of thermal properties of thin solid samples by photoacoustic techniques *Int J Therm Sci* 109 217:230 (2016) <https://doi.org/10.1016/j.ijthermalsci.2016.06.005>
- [103] G. W. A. Dummer, *Electronic Inventions and Discoveries: Electronics from Its Earliest Beginnings to the Present Day*. Elsevier (2013) ISBN [9780750304931](https://www.isbn-international.org/product/9780750304931) - CAT# [IP250](https://www.isbn-international.org/product/9780750304931)
- [104] E. Dorschky, D. Krüger, N. Kurfess, H. Schlarb, S. Wartzack, B. Eskofier, A. J. van den Bogert, Optimal control simulation predicts effects of midsole materials on energy cost of running, *COMPUT METHOD BIOMEC* (2019) ISSN:1025-5842 DOI: [10.1080/10255842.2019.1601179](https://doi.org/10.1080/10255842.2019.1601179)
- [105] N. Astrath, F. Astrath, B.G. Francine, J. Shen, C. Lei, J. Zhou, Z.S. Liu, T. Navessin, M. Baesso, A. Bento, An open-photoacoustic-cell method for thermal characterization of a two-layer system, *J APPL PHYS*, 107 4 043514-1-043514-5 (2010) <https://doi.org/10.1063/1.3310319>
- [106] V. A. Fishman and J. A. Bard, Open-Ended Photoacoustic Spectroscopy Cell for Thin-Layer Chromatography and Other Applications, *Anal. Chem.* 53 102–105 (1981) <https://doi.org/10.1021/ac00224a026>

- [107] D. Zibar, M. Piels, R. T. Jones, C. G. Schaeffer. Machine learning techniques in optical communication. *J LIGHTWAVE TECHNOL*,34 (6), 1442-1452. (2016) <https://doi.org/10.1109/JLT.2015.2508502>
- [108] M. Nestic, S. Galovic, S. Todosijevic, M. Popovic, Z. Soskic, Stacionarni fototermalni efekat: Uticaj višestrukih optičkih refleksija, XII Congress of Serbian Physicists, Book of Papers, Publisher: COBISS.SR-ID 198025740 (2013) ISBN [978-86-86169-08-2](https://doi.org/10.1109/JLT.2015.2508502)
- [109] M. Nestic, M. Popovic, S. Galovic, The influence of multiple optical reflexions on the photoacoustic frequency response, *Optical and Quantum Electronics* 48(5) (2016) DOI:[10.1007/s11082-016-0564-4](https://doi.org/10.1007/s11082-016-0564-4)
- [110] A. Y. Lokhov, D. Saad, Optimal deployment of resources for maximizing impact in spreading processes, *Proceedings of the National Academy of Sciences of the United States of America*, 114 (39): E8138 - E8146 (2017) DOI: [10.1073/pnas.1614694114](https://doi.org/10.1073/pnas.1614694114)
- [111] Guozhong An, The Effects of Adding Noise During Backpropagation Training on a Generalization Performance, *Neural Comput*, Vol8, 3 p. 643 - 674 (1996) <https://doi.org/10.1162/neco.1996.8.3.643>
- [112] J. C. Chuan Wang, Principe, Training neural networks with additive noise in the desired signal, *Neural Networks IEEE Transactions on*, vol. 10, no. 6, pp. 1511 -1517 (1999) doi>[10.1109/72.809097](https://doi.org/10.1109/72.809097)
- [113] K. Lj. Djordjevic, S. P. Galovic, M. I. Jordovic-Pavlovic, Z. M. Cojbasic, D. D. Markushev, Improvement of Neural Networks Applied to Photoacoustic Signals of Semiconductors With Added Noise, *Silicon*, under review.
- [114] I. Isaev and S. Dolenko, Training with Noise Addition in Neural Network Solution of Inverse Problems: Procedures for Selection of the Optimal Network, *Procedia Comput. Sci.* 123, 171-176 (2018) doi.org/10.1016/j.procs.2018.01.028
- [115] Yong-Bin Kim, Challenges for nanoscale MOSFETs and emerging nanoelectronics, *Trans. Electr. Electron. Mater.* 11 3 1229-7607(2010) DOI: [10.4313/TEEM.2010.11.3.093](https://doi.org/10.4313/TEEM.2010.11.3.093)

5. ЗАКЉУЧАК

5.1. Општа запажања

У овом раду је показано да добро одабране неуронске мреже могу да се користе као ефикасни метод за предикцију карактеристичних параметра узорка Si n-типа: коефицијента термалне дифузије, коефицијента топлотног ширења и дебљине узорка из фотоакустичких експерименталних сигнала. Под ефикасним методом подразумевамо изузетно високу поузданост неуронске мреже, прецизност реда промила и брзо добијање резултата реда микро секунде (рад у реалном времену).

За разлику од стандардног приступа обуке мреже експерименталним подацима, у тези је развијен приступ обуке великим сетом амплитуда и фаза фотоакустичког сигнала израчунатих применом теоријског модела за фотоакустички одзив плазма-дебелих полупроводника у опсегу модулационих фреквенција од 20Hz до 20kHz. Показано је да тако обучене неуронске мреже могу да достигну велику прецизност и поузданост у предикцији параметара експериментално добијених фотоакустичких сигнала.

Анализиран је рад неуронских мрежа у зависности од типа података на улазу и излазу и показано је да најбоље карактеристике имају мреже обучаване са амплитудама и фазама, упркос очекивању заснованом на теоријском моделу који показује да и амплитуде и фазе зависе од истих параметара. Указано је на важност нормализације улазних параметара ради свођења њихових вредности на исти ниво, како би мрежа испунила све захтеве везане за прецизност и поузданост. Утврђено је да су мреже обучаване само амплитудама или само фазама мање прецизне.

Развијене мреже су примењене за обраду експерименталних резултата мерења и предикцију параметара силицијума n-типа. Испитивана је прецизност и поузданост мрежа, као и брзина обраде експерименталних података. Истакнута је неопходност прилагођавања експерименталних фреквенција сигнала фреквенцијама тренинга неуронске мреже. Показано је да и на експерименталним сигналима мреже могу дати прецизну и поуздану предикцију параметара полупроводника. Повратком тих параметара у теоријски модел извршена је додатна анализа транспортних процеса и њихових ефеката, и на тај начин је проверена стабилност експерименталне поставке, што јесте суштина решавања инверзног проблема.

Показано је да се веома прецизним мрежама обученим на теоријским сигналима могу, процедуром повратка уназад (Reverse back procedure), кориговати оптички параметри

у експерименталној поставци, јер се разлике које се јављају у предикцији експерименталних фотоакустичких сигнала могу приписати експерименталним условима. Тако се обученим мрежама може и кориговати експериментална поставка у односу на флукутације извора зрачења и у односу на стања површина анализираног узорка кроз анализу коефицијента апсорпције и коефицијента рефлексije испитиваног полупроводничког материјала.

Направљена је генерализација мреже додавањем различитог степена шума сигнаlima за обуку, и показало се да се и на тај начин долази до постизања оптималних перформанси мреже у смислу рада у реалном времену, поузданости и прецизности уз смањење времена обуке. На исти начин потврђена је, такође, оправданост коришћења неуронских мрежа тренираних на амплитудама и фазама у карактеризацији плазма-дебелих узорака полупроводника, и то све кроз анализу како теоријских тако и експерименталних података.

Добијени резултати у овој тези показују да фотоакустика у спрези са применом неуронских мрежа постаје конкурентна техника којом се брзо, прецизно и поуздано може извршити предикција тражених параметара полупроводника и његова потпуна карактеризација у фреквентном домену.

5.2. Правци даљих истраживања

Када се говори о правцима даљег развоја неуронске мреже оптимизацијом њеног улазног и излазног вектора, у сврху инверзног решавања фотоакустичког проблема код полупроводника, отвара се могућност значајног скраћења мерне процедуре, јер је показано да задовољавајуће прецизан и поуздан рад добро обучена мрежа може постићи и мањим бројем мерних тачака. Морамо имати у виду да је прикупљање експерименталних података у фреквентно зависној фотоакустици полупроводника временски захтеван процес, јер се мерења могу изводити: а) у више просторних тачака на великом узорку (multi point measurements), б) у једној просторној тачки на неколико десетина различитих фреквенција (several point measurements). У раду је показано да се прилагођавањем фотоакустичког мерења одговарајућим експерименталним условима, кроз коришћење узорака облика малих плочица милиметарских димензија и микрометарских дебљина, постиже потребан услов мерења у једној просторној тачки (single point measurement) што је довољно за поуздану карактеризацију полупроводника. Основна мотивација је да такву карактеризацију материјала учинимо и врло брзом, у реалном времену (real time measurement), што значи да сведемо мерења у једној тачки на мали број различитих фреквенција, тежећи ка идеалном случају мерења на само једној фреквенцији (one point measurement). Предлог за даља

истраживања био би да се избор и смањење броја мерних тачака препустити неком од познатих алгоритама, нпр. PCI Decision Making Algorithm, који би се комбиновао са одређеним степеном експертског знања. На тај начин читав процес прикупљања и обраде података заједно са предикцијом карактеристичних параметара узорка могао би довести до тога да фотоакустичка метода постане још конкурентнија осталим експерименталним методама испитивања материјала.

Један од праваца даљег истраживања је повећање броја параметара неурона излазног вектора. Као друго, мрежа се може обучавати са моделима прилагођеним плазма-танким узорцима код којих би се, под одређеним условима, могао директно добити допринос плазмаеластичних ефеката, што значи проширење параметара предикције на електронске параметре узорка: коефицијент електронске деформације и коефицијент амбиполарне дифузије. Као треће, мрежа се може обучавати и теоријским моделима који се односе на вишеслојне структуре. То се првенствено односи на моделе фотоакустичког одзива танких филмова депонованих на силицијумским супстратима (чије су дебљине у области плазма-дебелих узорака). Овакви теоријски модели већ постоје и претпоставка је да могу послужити за обуку мреже са много већим бројем излаза (најмање шест, по три за сваки слој) без значајнијег смањења брзине, тачности и поузданости предикције.

Биографија

Катарина Ђорђевић је рођена 03.05.1971 у Нишу. По завршетку гимназије „Светозар Марковић“ уписује студије Опште физике на Филозофском Факултету Универзитета у Нишу. Дипломирала је 1997-е године са просечном оценом 9.31 одбраном дипломског рада „Фазни прелази He3 и He4“. Уписала је магистарске студије на Физичком факултету Универзитета у Београду на смеру Физика кондензоване стања где је одбранила магистарску тезу под називом “Статистка разгранатих полимера на једној класи хијерархијских решетки“ под менторством проф.др Милана Кнежевића 2009-е године. Докторске студије на Физичком факултету је уписала 2017-е, под руководством ментора др. Драгана Маркушева, научног саветника Института за физику, Земун-Београд, Универзитета у Београду.

Ужа област истраживања Катарине Ђорђевић је физика кондензованог стања. У оквиру тога, посебно се истичу њена истраживања у фотоакустици и примени неуронских мрежа у обради експерименталних резултата као и у инверзном решавању фотоакустичког проблема.

Изјава о ауторству

Име и презиме аутора: **Катарина Ђорђевић**

Број индекса: **8017/2017**

Изјављујем

да је докторска дисертација под насловом:

Примена неуронских мрежа у фотоакустичкој анализи

силицијума n-типа у фреквентном домену

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршила ауторска права и користила интелектуалну својину других лица.

Потпис аутора

У Београду, 22. 06. 2020

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: **Катарина Ђорђевић**

Број индекса: **8017/2017**

Студијски програм: **Физика кондензованог стања**

Наслов рада: **Примена неуронских мрежа у фотоакустичкој анализи
силицијума n-типа у фреквентном домену**

Ментор: **др Драган Маркушев**

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла ради похрањивања у **Дигиталном репозиторијуму Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис аутора

У Београду, 22.06.2020

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Примена неуронских мрежа у фотоакустичкој анализи силицијума п-типа у фреквентном домену

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци.

Кратак опис лиценци је саставни део ове изјаве).

Потпис аутора

У Београду, 22. 06. 2020

1. Ауторство. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

2. Ауторство – некомерцијално. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

3. Ауторство – некомерцијално – без прерада. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

4. Ауторство – некомерцијално – делити под истим условима. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

5. Ауторство – без прерада. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

6. Ауторство – делити под истим условима. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.