



ULBS

Universitatea "Lucian Blaga" din Sibiu



Scoala doctorală interdisciplinară

Domeniul de doctorat: Inginerie industrială

Teză de doctorat

DEVELOPING AND IMPLEMENTING AN ALGORITHM AND
DEVICE FOR ASSESSING THE MICRO AND NANOPARTICLE
SIZE BASED ON DYNAMIC LIGHT SCATTERING PROCEDURE

- REZUMAT -

Doctorand:

SILVIU-MIHAI REI

Conducător științific:

Prof. univ. dr. ing. DAN CHICEA



CUPRINS.....	I
CUVINTE CHEIE	II
LISTA LUCRĂRILOR PUBLICATE ȘI ALTE CONTRIBUȚII	III
REZUMAT	VI
1. INTRODUCERE	VI
2. FUNDAMENTELE TEORETICE ALE ÎMPRĂȘTIERII DINAMICE A LUMINII (DLS).....	IX
3. DEZVOLTAREA UNUI SISTEM DE ACHIZIȚIE DE DATE PENTRU MĂSURĂTORI DLS	XVI
4. DEZVOLTAREA ALGORITMULUI PENTRU PROCESAREA DLS.....	XXI
5. REZULTATE PRELIMINARE ȘI TESTE.....	XXIV
6. REZULTATE EXPERIMENTALE ȘI REZULTATE DE PERFORMANȚĂ.....	XXXV
7. IMPLEMENTARE ALTERNATIVĂ A UNEI REȚELE NEURALE ARTIFICIALE PENTRU MĂSURĂTORI DLS.....	L
8. IDEI ADIȚIONALE DE DEZVOLTARE	LV
9. CONCLUZII	LV
10. BIBLIOGRAFIE.....	Error! Bookmark not defined.

CUVINTE CHEIE

Împrăștierea dinamică a luminii, rețele neuronale artificiale, dimensiunea particulelor, nano-particule, micro-particule, achiziție de timp, măsurători, serii de timp, procesarea semnalelor.

LISTA LUCRĂRILOR PUBLICATE ȘI ALTE CONTRIBUȚII

LISTA LUCRĂRILOR PUBLICATE

A. ISI

1. **Dan Chicea, Silviu Rei**, *A FAST ARTIFICIAL NEURAL NETWORK APPROACH FOR DYNAMIC LIGHT SCATTERING TIME SERIES PROCESSING*, Measurement Science and Technology, 29(2018) 105201 (15pp), IOP Publishing, <https://doi.org/10.1088/1361-6501/aad937> (Q2)

B. SCOPUS

1. **Silviu Rei**. *IMPLEMENTING A LOW COST DATA ACQUISITION SYSTEM FOR EDUCATION PROGRAMS IN UNIVERSITIES*. Balkan Region Conference on Engineering and Business Education 3 (1) (2017), 130-136.
2. **Dan Chicea, Silviu Rei**. *TIME SERIES SPACE PHASE QUALITATIVE ANALYSIS AND A POSSIBLE APPLICATION*. Academic Journal of Manufacturing Engineering . 2015, Vol. 13 Issue 2, p148-153. 6p. Paper also presented in the conference.

C. BDI

1. **Silviu Rei, Dan Chicea**. *USING DYNAMIC LIGHT SCATTERING EXPERIMENTAL SETUP AND NEURAL NETWORKS FOR PARTICLE SIZING*. ACTA Universitatis Cibiniensis 69 (1), 155-161. Paper also presented at the 3rd International Conference for Doctoral Students - IPC 2017 June 22-23, 2017.Brașov, Romania.
2. **Silviu Rei, Dan Chicea, Beriliu Ilie, Sorin Olaru**. *DYNAMIC LIGHT SCATTERING SIGNAL CONDITIONING FOR DATA PROCESSING*. ACTA Universitatis Cibiniensis 69 (1), 130-135. Paper also presented at the 3rd International Conference for Doctoral Students - IPC 2017 June 22-23, 2017.Brașov, Romania.
3. **Silviu Rei, Dan Chicea, Sorin Olaru**. *AUTOCORRELATION FUNCTION ANALYSIS IN PROCESSING STOCHASTIC TIME SERIES*. Annals of the University

Dunarea de Jos of Galati: Fascicle II, Mathematics, Physics, Theoretical Mechanics .
2016, Vol. 39 Issue 1, p57-60. 4p.

4. **Dan Chicea, Silviu Rei.** *USING THE FOURIER TRANSFORM AND THE POWER SPECTRAL DENSITY FUNCTIONS FOR PATTERN RECOGNITION IN DYNAMIC LIGHT SCATTERING TIME SERIES.* Proceedings of the Fourth International Conference: Modelling and Development of Intelligent Systems Sibiu, Romania. 2015. p33-39. Paper also presented in the conference.

D. CONFERENCE PROCEEDINGS

1. **Dan Chicea, Silviu Rei, Dan Leca.** *MONITORING YEAST CELLS SIZE DURING FERMENTATION USING DYNAMIC LIGHT SCATTERING.* 9th Central European Congress on Food (CEFood), 24-26 May 2018, Sibiu, Romania.
2. **Dan Chicea, Silviu Rei.** *A FAST ALGORITHM FOR DLS TIME SERIES PROCESSING FOR MONITORING THE SIZE OF THE SUSPENDED PARTICLES IN WASTEWATER.* 18th International Balkan Workshop on Applied Physics and Materials Science, Constanta, Romania 10-13 July 2018.
3. **Dan Chicea, Silviu Rei, Liana Chicea.** *A FAST ALGORITHM FOR PROFILING SUSPENSIONS IN NATURAL WATER USING DYNAMIC LIGHT SCATTERING AND ARTIFICIAL NEURAL NETWORK PROCEDURE.* Presented at AQUATIC BIODIVERSITY INTERNATIONAL CONFERENCE 2017, Sibiu.
4. **Dan Chicea, Silviu Rei.** *SIMPLE ALGORITHMS TO GENERATE DYNAMIC LIGHT SCATTERING TIME SERIA.* Proceedings of the 16th International Balkan Workshop on Applied Physics, Constanta, Romania, July 7-9, 2016.S2-P19, p96. Paper also presented in the conference.
5. **Dan Chicea, Silviu Rei.** *A NONCONVENTIONAL PROCEDURE FOR DLS TIME SERIES PROCESSING.* Proceedings of the 16th International Balkan Workshop on Applied Physics, Constanta, Romania, July 7-9, 2016.S2-P22, p97. Paper also presented in the conference.

ALTE CONTRIBUȚII

1. **Contribuție semnificativă:** Dan Chicea. "Using neural networks for dynamic light scattering time series processing." *Measurement Science and Technology* 28.5 (2017): 055206.
2. **Contribuție minoră:** Dan Chicea. "DYNAMIC LIGHT SCATTERING TIME SERIES GENERATION USING HARMONIC FUNCTIONS". Proceedings of 17th International Balkan Workshop on Applied Physics Constanța, Romania, July 11-14, 2017

GRANTURI DE CERCETARE

- **JINR-RO 2018 04-4-1121-2015/2020 (JINR Dubna):** Advanced structural and magnetic investigations on FeCo/Al₂O₃ nanocomposites for novel soft magnetic materials for high frequency applications
- **JINR-RO 2018 04-4-1121-2015/2020 (JINR Dubna):** Co-based magnetic nanostructured material with potential space applications – synthesis and complex characterisation for novel soft magnetic materials for high frequency applications

REZUMAT

Textul acestui rezumat conține porțiuni din publicația următoare:

Dan Chicea, Silviu Rei, A fast artificial neural network approach for dynamic light scattering time series processing, Measurement Science and Technology, 29(2018) 105201 (15pp), IOP Publishing, <https://doi.org/10.1088/1361-6501/aad937> [300].

1. INTRODUCERE

Dynamic Light scattering (DLS) este o metodă experimentală inovatoare pentru măsurarea proprietăților particulelor mici (în intervale de la 10^{-9} - 10^{-6} m) găsite în suspensii și coloizi [1]. Metoda este utilizată pentru a determina raza hidrodinamică a particulelor dar poate fi utilizată și pentru determinarea vitezei de deplasare a particulelor sau analiza fluxului în fluide.

Metoda presupune iluminarea unei probe de fluid care conține particule mici de interes cu un fascicul monocromatic de lumină coerentă. Fiecare particulă absoarbe și re-emite lumină acționând ca o sursă secundară de lumină. Pe măsură ce particulele se mișcă termic, undele luminoase secundare se suprapun și produc modele de interferență. Imaginea de împrăștiere care se observă într-un câmp îndepărtat este de picățele în fierbere (engl. "boiling speckles"). Tehnica măsoară variația de intensitate a luminii la un punct fix. Măsurătoarea e înregistrată într-o serie de timp, serie care este folosită pentru a extrage parametrii particulelor de interes.

În lucrarea de față vom fi în principal interesați în extragerea informației cu privire la dimensiunea particulelor prin analiza seriilor de timp obținute dintr-un experiment tipic DLS folosind o procedură nouă asistentă de o rețea neurală artificială. Metoda pe care am considerat-o de referință pentru procesarea seriilor de timp DLS constă în fitarea formei analitice a funcției Lorentz peste spectrul de frecvență al intensității luminii împrăștiate înregistrate. Am proiectat și testat un set de rețele neurale artificiale. Datele de instruire a rețelei au constatat dintr-un set mare de siruri de autocorelații pentru serii de timp simulate pentru particule sferice monodisperse cu diametru cuprins în intervalul $10-3000 \mu\text{m}$. Precizia rețelelor neurale artificiale a fost testată atât pe serii de timp simulate cât și pe serii de timp experimentale înregistrate pe fluide care conțin nanoparticule și microparticule. Vom prezenta mai departe, pe scurt, un rezumat al ideilor și rezultatelor prezentate pe larg în teza asociată acestui rezumat.

Particulele, fie nanoparticule sau microparticule, atunci când sunt suspendate într-un fluid purtător, au o mișcare complexă constând atât în mișcarea de sedimentare cât și în mișcarea aleatoare, browniană [17. 264]. Atunci când o rază de lumină este incidentă pe un fluid care conține particule în suspensie, fiecare particulă absoarbe lumină și devine o sursă secundară având loc fenomenul de împrăștiere elastică a luminii. Vom numi aceste particule centre de împrăștiere (SC – scattering centers). În cazul în care fasciculul de lumină incident este coerent, undele împrăștiate vor fi coerente de asemenea, și, în consecință, acestea vor interfera. Consecința mișcării complexe a centrilor de împrăștiere este caracterul dinamic al câmpului de interferență, care apare ca „boiling speckles“. Mai multe articole descriu variația câtorva parametri, cum ar fi intensitatea luminii sau dimensiunea de speckle, cu dimensiunea și concentrația centrilor de împrăștiere, referințele [264. 265. 266] fiind câteva dintre acestea. Metoda care folosește corelarea dinamicii intensității luminii cu mișcarea browniană se numește Photon Correlation Spectroscopy (PCS) sau Dynamic Light scattering (DLS) iar baza teoretică a acestei metode este explicată în mai multe studii, cum ar fi [1], [7], [33], [267], [268].

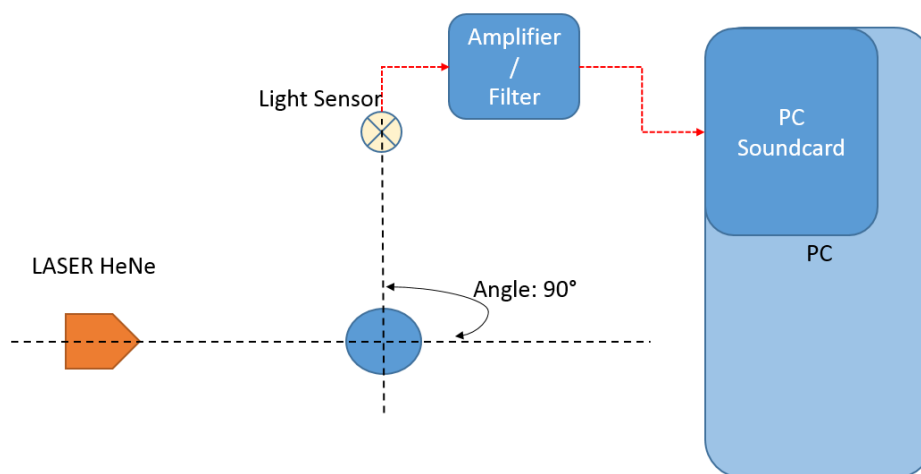
În perioada de pionierat a metodei DLS, au fost utilizate ca detectoare tuburile fotomultiplicatoare (PMT). Acestea au un răspuns rapid, liniar într-o gamă largă, cu o amplificare foarte bună și un puls îngust, în intervalul de nanosecunde [105]. Ulterior au fost folosite fotodiode (PD) cu îmbunătățirea numită fotodiode de avalanșă (APD). Mai târziu au fost introduse diode P-I-N deoarece acestea îmbunătățesc eficiența dispozitivului [105]. O altă parte tipică a dispozitivului DLS a fost autocorrelatorul. Acesta conținea hardware-ul pentru a calcula în timp real autocorelația semnalului înregistrat.

Odată cu trecerea timpului, metoda DLS a fost îmbunătățită în continuare. O diodă laser poate fi utilizată astăzi ca sursă de lumină coerentă. O fotodiodă cu un sistem de achiziție de date pot fi folosite pentru a înregistra seriile de timp DLS pe un PC care poate fi utilizat pentru a procesa aceste serii de timp. Exemple de construcții experimentale simple dar funcționale pot sunt descrise în lucrări cum ar fi [105] și [269], printre altele. Anumite îmbunătățiri se pot face în continuare în procesarea seriilor de timp, pentru a crește viteza procesului de calcul și a reduce intensitatea calculului necesar, cu scopul de a transforma DLS într-o procedură de măsurare a particulelor în timp real. Am considerat că utilizarea rețelelor neurale artificiale poate fi o alternativă pentru a realiza acest scop.

O rețea neurală artificială (ANN) este o implementare pe un calculator a unui model care imită structura biologică a unui creier. O astfel de rețea poate fi descrisă ca fiind un

obiect care are o ieșire care depinde de un set de valori de intrare și care utilizează neuroni artificiali, pentru a procesa informația pe baza unor așa-numite funcții de transfer. Neuronii artificiali sunt interconectați iar conexiunile sunt descrise folosind ponderi. Aceste interconexiuni complexe permit codului rețelei să „învețe“, sau să actualizeze iterativ ponderile folosind un set mare de valori de intrare într-o astfel încât să poată calcula ieșirile de dorit.

Odată ce o rețea este pregătită, se pot efectua diferite sarcini care emulează acțiuni inteligente. Una dintre aceste acțiuni poate fi aceea de a calcula valoarea unei funcții care are o formă analitică necunoscută, bazată pe pregătirea unei rețele cu seturi de date de intrare, cu ieșire cunoscută. Recunoașterea unor modele, cum ar fi fețe sau clasificarea obiectelor, procesarea imaginilor, filtrarea sunetului, rezolvarea problemelor de regresie, sunt alte câteva exemple în care rețelele neurale artificiale sunt utilizate cu succes. Limitele în utilizarea rețelelor neurale artificiale sunt impuse doar de imaginație și de abilitățile în reprezentarea corectă a problemei, în limitele teoremei de aproximare universală [172. 173. 174]. Acest lucru înseamnă cel mai des selectarea corectă a tipului de rețea, a algoritmului de formare precum și selecția setului de date pentru instruirea rețelei. Conceptul de rețea neurală artificială nu este nou, fiind explicat în detaliu în cărți cum ar fi [178] și [270].



D

Figura 1. Exemplu de dispozitiv DLS experimental

etele

le

neurale artificiale au fost luate în considerare anterior pentru prelucrarea datelor în fizică și în special, în optică. Referința [271] conține un studiu privind utilizarea semnăturii luminii polarizate sub forma unei matrici Mueller ca intrare pentru o rețea. O rețea neurală artificială a fost folosită cu succes pentru a detecta aminoacizi și alți compuși organici solizi. Referința

[272] prezintă un studiu privind utilizarea unei rețele artificiale neurale pentru a evalua dimensiunea și dependența de unghiul de împrăștiere a indicelui de refracție în măsurători de împrăștiere a luminii. Referința [273] prezintă o procedură pentru măsurarea razei particulelor sferice folosind distribuția unghiulară a luminii dispersate și o rețea neurală artificială cu 3 straturi. În [274] autorii prezintă o rețea neurală artificială instruită pentru recunoașterea modelelor într-un citometru de flux, împreună cu rezultatele în identificarea prezenței fibrelor periculoase, cum ar fi azbestul, în aer. Referința [275] prezintă rezultatele privind evaluarea dimensiunii și a indicelui de refracție al particulelor în suspensie din măsurători de difuzie a luminii dependente de unghi folosind o rețea neurală artificială bazată pe o funcție radială.

Studiul nostru ar trebui să fie privit ca fiind un pas înainte spre proiectarea unui dispozitiv miniaturizat independent DLS pentru evaluarea dimensiunilor particulare, dispozitiv care utilizează o platformă de calcul foarte ușoară, în locul unui PC sau un laptop.

Montajul experimental utilizat pentru testarea algoritmului propus, prezentat în Figura 1 constă dintr-un laser He-Ne, cu o putere de 10 mW, care lucrează în regim continuu, un tub de sticlă circular de 5 ml pentru probă, un detector, un preamplificator cu un răspuns liniar în gama de frecvențe audio și un PC.

2. FUNDAMENTELE TEORETICE ALE ÎMPRĂȘTIERII DINAMICE A LUMINII (DLS)

Datorită mișcării browniene, particulele din proba supusă măsurătorii sunt în mod constant într-o rotație și translație, ceea ce creează fluctuații ale constantei dielectrice a mediului. Particulele în suspensie pot fi privite ca surse de lumină secundare. Dacă lumina incidentă este coerentă, undele de lumină secundare emise de aceste surse sunt și ele coerente, prin urmare ele interferează, atât în mod constructiv cât și distructiv, ceea ce duce la o aspectul câmpului de interferență de „boiling speckles“. Fluctuația intensității luminii dispersate într-un punct este rezultatul schimbării în fază a luminii dispersate. Cu cât particulele se mișcă mai repede în fluid, cu atât fluctuațiile intensității măsurate sunt mai rapide. De asemenea, observăm intuitiv, că din cauza mișcării browniene particulele mai mici se mișcă mai repede decât particulele mai mari. Acestu lucru se poate observa și studiind relația Einstein-Stokes [1].

$$D = \frac{k_B T}{3\pi\eta d} \quad (1)$$

În (1) D este coeficientul de difuzie care indică cât de repede difuzează particulele, k_B este constanta lui Boltzmann, η coeficientul de viscozitate dinamică a solventului, T temperatura eșantionului și d diametrul hidrodinamic al particulei.

Abordarea pe care ne vom baza ca și cadru și de la care vom porni dezvoltarea noastră ulterioară este descrisă în detaliu în [1], [6], [104], [105]. Metoda utilizează serii de timp înregistrate pentru împrăștierea dinamică a luminii măsurate cu un sistem de achiziție de date, iar apoi calculează densitatea spectrală de putere care reprezintă spectrul de frecvență al seriei de timp a intensității înregistrate experimental pentru luminii dispersate. Densitatea spectrală de putere este apoi fitată folosind funcția Lorentz descrisă de ecuația (2), utilizând o procedură de minimizare neliniară de tip cele mai mici pătrate, determinând parametrii potriviți ai funcției.

$$S(f) = a_0 \frac{a_1}{(2\pi f)^2 + a_1^2} \quad (2)$$

În această expresie, f reprezintă frecvența spectrului iar a_0 și a_1 parametri. Parametrul a_0 scalează forma funcției pentru a ajunge la valoarea inițială. Parametrul a_1 este direct legat de mărimea particulelor, conform ecuației (3).

$$R = \frac{2\pi k_B T q^2}{6\pi\eta a_1} \quad (3)$$

În această ecuație (3), variabilele au următoarele semnificații: k_B – constanta lui Boltzmann, η - coeficientul de viscozitate dinamică a solventului, T - temperatura eșantionului, q - modulul vectorului de împrăștiere, așa cum este descris de ecuația (4).

$$q = \frac{4\pi n}{\lambda} \sin\left(\frac{\theta}{2}\right) \quad (4)$$

În ecuația (4), n este indicele de refracție al solventului, λ este lungimea de undă a luminii laser în vid și θ este unghiul de împrăștiere. Procedura implică găsirea celor doi

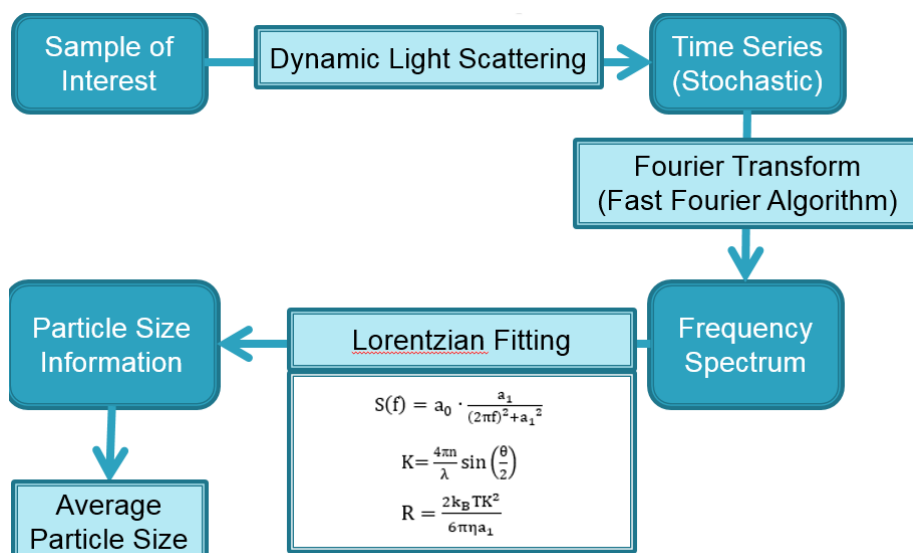


Figura 2. Diagrama procedurii de referință DLS

parametri și apoi, pe baza parametrului a_l , estimarea dimensiunii medii a particulei, folosind ecuația (3). Această metodă a fost considerată de noi ca metodă de referință pentru evaluarea diametrelor DLS, numite mai departe diametre DLS de referință. Figura 2 ilustrează diagrama procedurii DLS de referință.

Abordarea propusă de noi presupune în prim pas înlocuirea calculului spectrului de putere cu calculul autocorelării seriei de timp pentru intensitatea luminii în locul. Metoda propusă se bazează pe înregistrarea intensității luminii împrăștiată $I(\theta, t)$, calcularea autocorelării pentru seriile de timp înregistrate și apoi, folosind o metodă numerică neliniară prin cele mai mici pătrate, determinarea coeficientului de difuzie și, prin urmare, diametrul mediu hidrodinamic al particulelor.

Vom descrie mai departe pe scurt câteva elemente ale calculului autocorelării seriei de timp. Atunci când comparăm intensitatea luminii împrăștiată la două momente diferite, separate în timp prin τ , valorile vor fi cel mai probabil diferite și necorelate. În cazul în care timpul τ este comparabil cu timpul caracteristic al fluctuațiilor cele două valori vor fi destul de asemănătoare și cel mai probabil corelate. Cu creșterea valorii timpului de la zero la infinit corelația evoluează de la perfect corelate la deloc corelate. Fluctuațiile în intensitate sunt legate de mărimea particulelor. Particulele mai mici generează fluctuații rapide, funcția de autocorelație scazând mai repede decât pentru particule mai mari.

Pentru o relație cantitativă există diferite moduri de a extrage aceste informații din seriile de timp. Metoda pe care o vom considera ca referință utilizează funcția de corelare de timp pentru intensitate, definită ca:

$$G^{(2)}(\vec{q}, \tau) = \langle I_s(\vec{q}, t) I_s(\vec{q}, t + \tau) \rangle \equiv \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T I_s(\vec{q}, t) I_s(\vec{q}, t + \tau) dt \quad (5)$$

După cum se poate vedea în definiția funcției de autocorelație, intensitatea luminii la momentul t , este comparată cu același semnal, dar întârziat cu timpul τ , pentru toate valorile timpului, variind de la 0 la infinit. La momentul zero, semnalul este perfect corelat: $I_s(\vec{q}, t) I_s(\vec{q}, t + \tau)$

$$\lim_{\tau \rightarrow 0} \langle I_s(\vec{q}, 0) I_s(\vec{q}, \tau) \rangle = \langle I_s^2(\vec{q}) \rangle \quad (6)$$

La un timp de întârziere mult mai mare decât timpul caracteristic al fluctuațiilor, $\tau \gg T_C$, semnalul nu mai este corelat deloc

$$\lim_{\tau \rightarrow \infty} \langle I_s(\vec{q}, 0) I_s(\vec{q}, \tau) \rangle = \langle I_s(\vec{q}) \rangle^2 \quad (7)$$

Aceasta înseamnă că autocorelația scade de la valoarea-medie pătratică a intensității la pătratul mediei.

Din motive practice am utilizat funcția de autocorelație normalizată:

$$g^{(2)}(q, \tau) \equiv \frac{\langle I_S(\vec{q}, 0) I_S(\vec{q}, \tau) \rangle}{\langle I_S(\vec{q}) \rangle^2} \quad (8)$$

O funcție similară de autocorelație poate fi calculată pentru câmpul electric

$$g^{(1)}(q, \tau) \equiv \frac{\langle E_S(\vec{q}, 0) E_S(\vec{q}, \tau) \rangle}{\langle E_S(\vec{q}) \rangle^2} \quad (9)$$

Cele două funcții de autocorelație sunt conectate prin relația Siegert [278], care, în forma sa cea mai generală poate fi exprimată ca:

$$g^{(2)}(q, \tau) = A \left(1 + \beta [g^{(1)}(q, \tau)]^2 \right) \quad (10)$$

Factorul β este un factor care descrie decoerenta spațială a luminii dispersate peste un detector, determinată de raportul: zona speckle-ului - zona detector, și având valori între 0 și 1. A determină linia de bază a funcției. În cazul în care suprafața detectorului este egală cu cea a speckle-ului, factorul de decoerență spațial este exact 1.

Pentru a conecta funcțiile de autocorelație definite mai sus cu dimensiunea particulelor, trebuie să luăm în considerare atât viscozitatea solventului și temperatura, cât și coeficientul de difuzie, D , care descrie mișcarea browniană a particulelor. Pentru un sistem polidispers de particule, și având în vedere cele de mai sus, autocorelația câmpului electric poate fi modelată ca o distribuție de exponențiale

$$g^{(1)}(\tau) = \int_0^\infty G(\Gamma) e^{-\Gamma\tau} d\Gamma \quad (11)$$

Unde $G(\Gamma)$ distribuția normalizată a exponențialelor iar $\Gamma = q^2 D$, cu q vectorul de împrăștiere și D coeficientul de difuzie. Această ultimă ecuație poate fi de asemenea exprimată ca o sumă de exponentiale, pentru o distribuție discontinuă, ca în ecuația (12):

$$g^{(1)}(\tau) = \sum_{n=1}^M A_n e^{-\Gamma_n \tau} \quad (12)$$

Pentru sistemele monodisperse adevărate autocorelația câmpului electric se reduce la o singură exponențială:

$$g^{(1)}(\tau) = e^{-\Gamma\tau} \quad (13)$$

În ecuația (12) coeficienții A_n descriu contribuțiile particulelor cu coeficienți de difuzie diferiți, deci particule de dimensiuni diferite, la rata globală de descompunere a funcției de autocorelație,:

$$D_{0n} = \frac{r_n}{q^2} \quad (14)$$

Cum ceea ce măsurăm este intensitatea luminii dispersate și nu câmpul electric ne vom întoarce la funcția de autocorelație a intensității, integrând toate informațiile de mai sus. Aceasta poate fi exprimată ca:

$$g^{(2)}(t) = 1 + \beta \sum_{i=1}^n a_i e^{-D_i q^2 t} \quad (15)$$

Sau

$$g^{(2)}(t) = 1 + \beta \int_0^\infty A(D) e^{-D q^2 t} dD \quad (16)$$

Pentru soluții monodisperse, funcția de autocorelație poate fi scrisă ca

$$g^{(2)}(t) = 1 + \beta e^{-D q^2 t} \quad (17)$$

Putem extinde procedura de normalizare prin scăderea 1 din partea dreaptă a ecuației (17), pentru a simplifica forma.

Problema evaluării diametrelor particulelor poate fi redusă la găsirea parametrilor funcției de autocorelație, mai precis coeficientul de difuzie D , care poate dezvălui apoi diametrele particulelor prin relația Einstein-Stokes. Acest lucru se poate face printr-o procedură de fitare prin minimizare neliniară prin cele mai mici pătrate, însă această variantă nu face obiectul acestei lucrări.

Abordarea propusă de noi se bazează pe o metodă numerică mult mai rapidă, care utilizează o rețea neurală artificială. Rețeaua are ca intrare funcția de autocorelație normalizată a semnalului de intensitate a luminii și oferă ca ieșire direct diametrul mediu al particulelor, într-un singur pas.

Figura 3 prezintă o imagine de ansamblu a procedurii. Fitarea numerică și calculele post-procesare au fost complet îndepărtate și înlocuite cu o rețea neurală articială care înlocuiește practice toate aceste acțiuni printr-un singur pas. Unul dintre principalele motive pentru care am folosit această abordare este pentru a putea miniaturiza sistemul de calcul utilizat. Vom descrie pe scurt care sunt motivele pentru care abordarea propusă permite miniaturizarea mai bine decât metoda de referință. Metoda clasică de referință necesită fitare numerică.

Experiența a arătat că metoda are nevoie de intervenție umană, pentru a regla parametrii de fitare, prin urmare, nu este complet automatizată.

De asemenea, metoda de referință are nevoie de un timp semnificativ de calcul. Fitarea în sine generează o mulțime de operațiuni cu virgulă mobilă și, și mai important, fitarea este necesară de fiecare dată când se evaluează un diametru. Din aceste motive, metoda clasică necesită o platformă de calcul care are suficientă putere și memorie, de obicei un PC. Metoda asistată de o rețea neurală artificială necesită într-adevăr instruirea rețelei, etapă care implică de asemenea un număr mare de operații de calcul dar acest lucru se face doar o singură dată. De îndată ce rețeaua ajunge la nivelul de maturitate necesar, ca urmare a instruirii, aceasta poate fi exportată într-o platformă de calcul mai slabă, fapt deosebit de important pentru

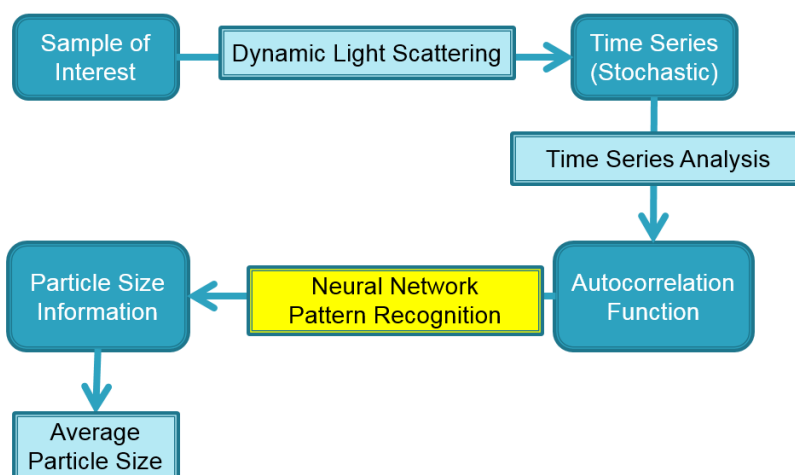


Figura 3. Procedurii DLS asistată de o rețea neurală artificială

miniaturizare.

Metoda asistată de o rețea neurală artificială are ca fundament teorema aproximației universale [172], [173], [174]. Această teoremă afirmă că o rețea de tip feed-forward cu un strat ascuns de dimensiuni finite poate aproxima funcții continue pe subseturi compacte ale R^n . Dacă φ este o funcție monotonă mărginită non-constantă continuă, I_m hiper-cubul unitate în m dimensiuni și $C(I_m)$ spațiul funcțiilor continue pe I_m atunci, pentru orice $\varepsilon > 0$ și orice funcție, există un număr întreg N , constantele $v_i, b_i \in R$ și vectorii $w_i \in R^m$, cu $i=1, \dots, N$, astfel încât funcția

$$F(x) = \sum_{i=1}^N v_i \varphi(w_i^T x + b_i) \quad (18)$$

este o aproximare a funcției f , unde f este independentă de φ , sau

$$|F(x) - f(x)| < \varepsilon \quad (19)$$

pentru toți $x \in I_m$. Acest lucru este valabil, de asemenea, atunci când I_m este înlocuit cu orice submulțime compactă sau R^n .

Aceasta înseamnă că o rețea de tipul descris poate funcționa ca un aproximator universal. Cybenko [172] a demonstrat că această teoremă este valabilă pentru funcțiile de activare sigmoide iar Hornik [173] a arătat că puterea de aproximare a rețelei nu este legată de funcția de activare ci de arhitectura sa, ceea ce a reprezentat de fapt o generalizare a teoremei de la funcțiile de activare sigmoide la orice funcții de activare.

3. DEZVOLTAREA UNUI SISTEM DE ACHIZIȚIE DE DATE PENTRU MĂSURĂTORI DLS

Problema determinării dimensiunii particulelor poate fi privită ca fiind echivalentă cu găsirea corespondenței între mulțimea funcțiilor de autocorelație și cea a diametrelor

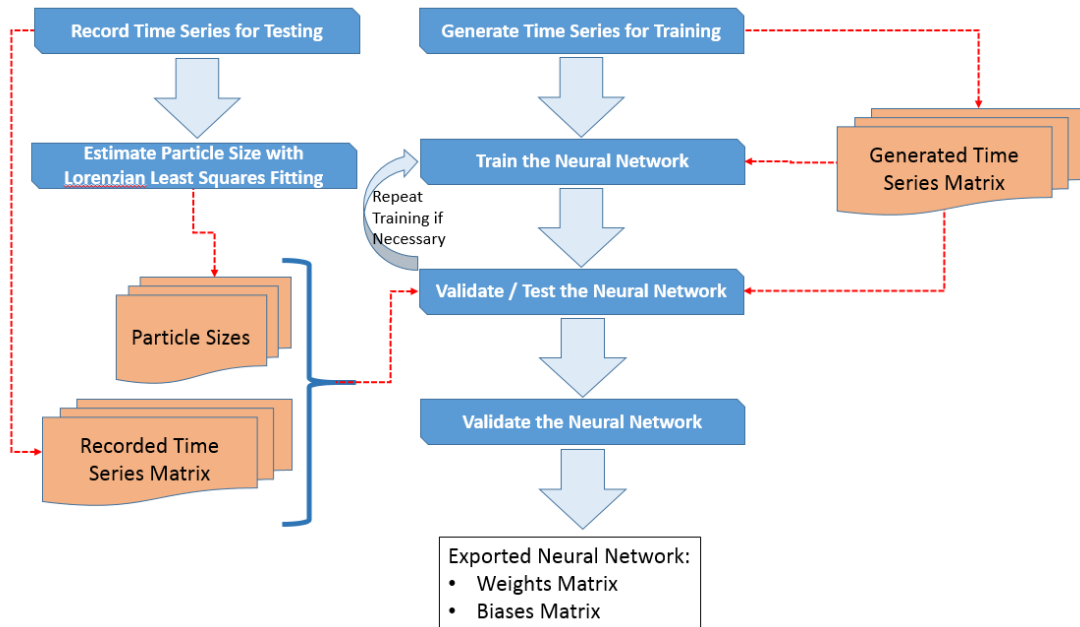


Figura 4. Procedura folosită la generarea rețelelor neurale artificiale

hidrodinamice medii ale particulelor în suspensie. Acest lucru este oarecum similar cu fitarea unei funcții matematice. Am emis ipoteza că această problemă poate fi rezolvată cu o rețea având o arhitectură, funcții de transfer și vectori de intrare și de instruire alese corespunzător. Pentru orice problemă care poate fi rezolvată cu o astfel de rețea reprezentarea corectă a problemei în spațiul rețelei neurale artificiale este deosebit de importantă.

După cum am menționat pe scurt, o rețea neurală artificială se bazează pe un număr de unități interconectate numite neuroni artificiali, unități structurate într-o anumită arhitectură, de obicei în straturi. Acești neuroni artificiali sunt capabili să comunice cu alți neuroni artificiali din cadrul rețelei. O rețea are în general mai multe componente-cheie care, împreună cu structura sa, definesc arhitectura rețelei: un set de unități elementare numite neuroni, conexiuni între unități definite de ponderi de conectare precum și un set de funcții de prelucrare a datelor. Aceste funcții pot fi: o funcție de propagare, o funcție de activare și o funcție de ieșire. De asemenea, strategia de învățare este inclusă în arhitectura rețelei, strategie care adaptează rețeaua adecvat la problema de rezolvat.

Pentru găsirea unei rețele optime pentru problema descrisă am folosit un algoritm care

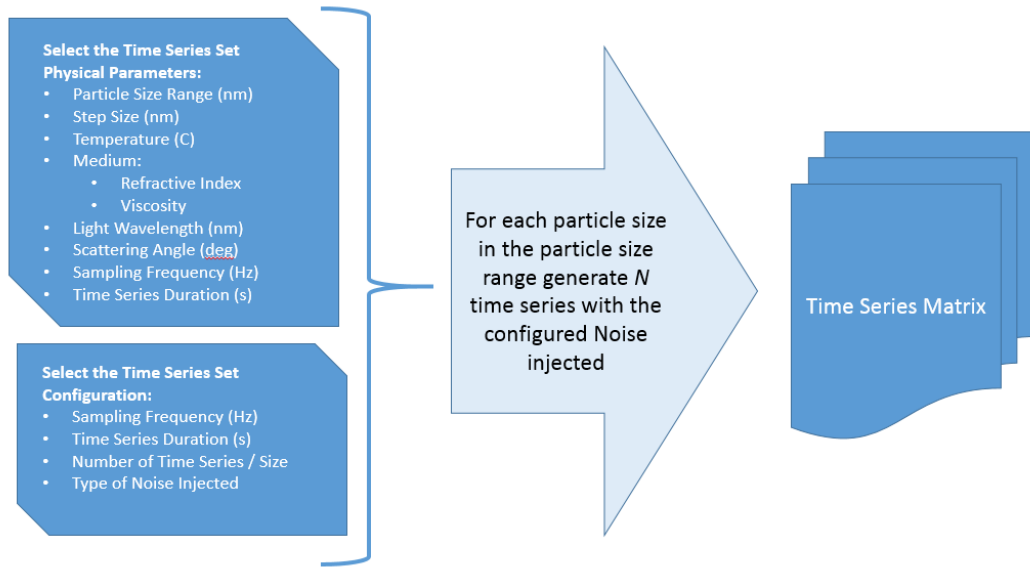


Figura 5. Procedura de generare a matricilor de serii de timp folosind metoda funcțiilor armonice

automatizează procesul, prezentat în Figura 4.

Setul de date de autocorelație utilizate în instruirea rețelei fost calculat pe serii de timp simulate care au avut injectate atât un zgomot de 50 Hz și armonicile acestei frecvențe precum și un zgomot aleator. Algoritmul folosit în generarea seriilor de timp DLS, cu zgomot, prezentat în Figura 5, reprezintă și el o abordare nouă fiind descris în detaliu în teza asociată acestui rezumat. Acest algoritm reprezintă o procedură simplă care utilizează funcții deterministice (funcții armonice) pentru a produce serii de timp caracteristice pentru un sistem stocastic.

Vom prezenta mai departe pe scurt câteva detalii de construcție ale unui dispozitiv DLS minaturizat, asistat de o rețea neurală artificială. Figura 6 prezintă arhitectura abstractă a dispozitivului menționat miniaturizat.

Următoarele module sunt considerate ca fiind părți ale sistemului:

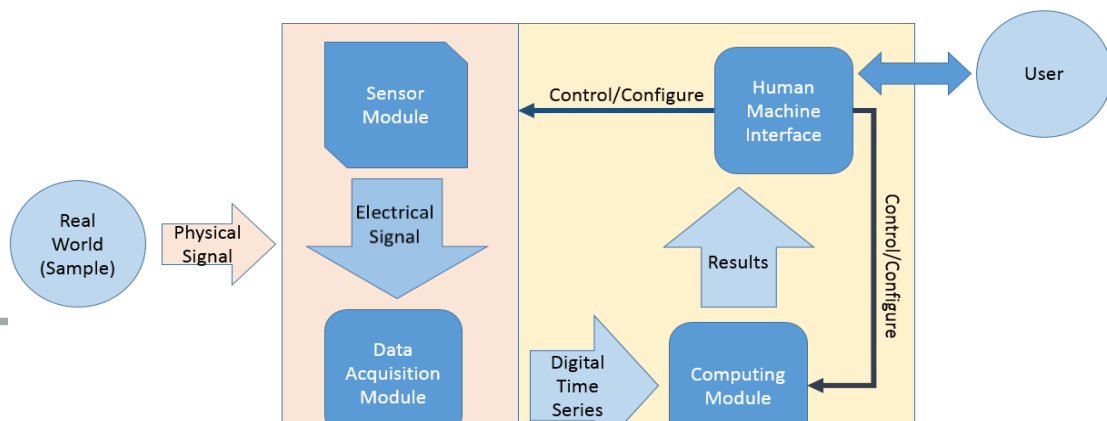


Figura 6. Arhitectura abstractă a dispozitivului DLS

- **Modulul senzor.** Acest modul are rolul de a transforma intensitatea luminii într-un semnal electric stabil și precis, în intervalele de tensiune cerute de modul următor.
- **Modulul de achiziție de date.** Acest modul are rolul de prelevare de probe și digitizarea semnalului electric care vine de la modulul de senzor.
- **Modulul de calcul.** Acest modul are ca date de intrare seriile de timp digitale și efectuează toate operațiile matematice necesare pentru a obține o estimare a dimensiunii particulelor.
- **Interfața utilizator-mașină.** Acest modul permite utilizatorului să configureze sistemul precum și să urmărească rezultatele estimării oferite de modulul de calcul.

Chiar dacă modulul senzor și modulul de achiziție de date sunt independente, ele vor lucra împreună în ceea ce a fost numit modulul de digitizare. De asemenea, modulul de calcul și interfața om-mașină nu sunt neapărat un singur modul însă ele lucrează împreună într-un modul numit modul utilizator-mașină-calcul.

Pentru a trece de la arhitectura abstractă la o imagine mai practică a dispozitivului vom descrie cele necesare pentru ca dispozitivul să funcționeze corect.

În paragrafele următoare vom expune o scurtă descriere a fiecărui modul.

Modulul senzor este responsabil pentru transformarea semnalului de intensitate a luminii într-un semnal electric. ieșirea acestuia este o tensiune analogică. Acest modul face un pic mai mult decât o măsurătoare. Modulul constă dintr-o diodă laser, un fotorezistor, un amplificator și o cuvă pentru probă. Dioda laser, datorită obiectivului de a avea întregul dispozitiv miniaturizat, este foarte mică, fiind similară cu o diodă laser pointer. Întregul modul trebuie să fie plasat într-o cameră întunecată, cu pereți de culoare neagră.

Modulul sensor-sistem de achiziție de date trebuie să fie construit într-un mod care să permită o flexibilitate maximă a dispozitivului. Datorită modelelor de interacțiune complexe ale parametrilor, după cum putem vedea în analiza prezentată în detaliu în această lucrare, sistemul trebuie să fie proiectat într-un mod care să permită sistemului să fie adaptabil la diferite tipuri de condiții. Am implementat două straturi de condiționare a semnalului, unul în hardware-ul sistemului, implementat în modulul senzor, și unul în software, pentru condiționarea seriilor de timp, după cum vom vedea în detaliu mai târziu.

Modulul senzor are 4 unități de detecție, plasate la unghiuri diferite și controlabile de la unitatea de comandă a modului de achiziție. Modulul senzor are, de asemenea, un laser și o cuvă pentru probă. Geometria unității de detecție este rezultatul investigațiilor efectuate și descrise în detaliu în această lucrare. Figura 7 prezintă schematic conceptul întregii unități de

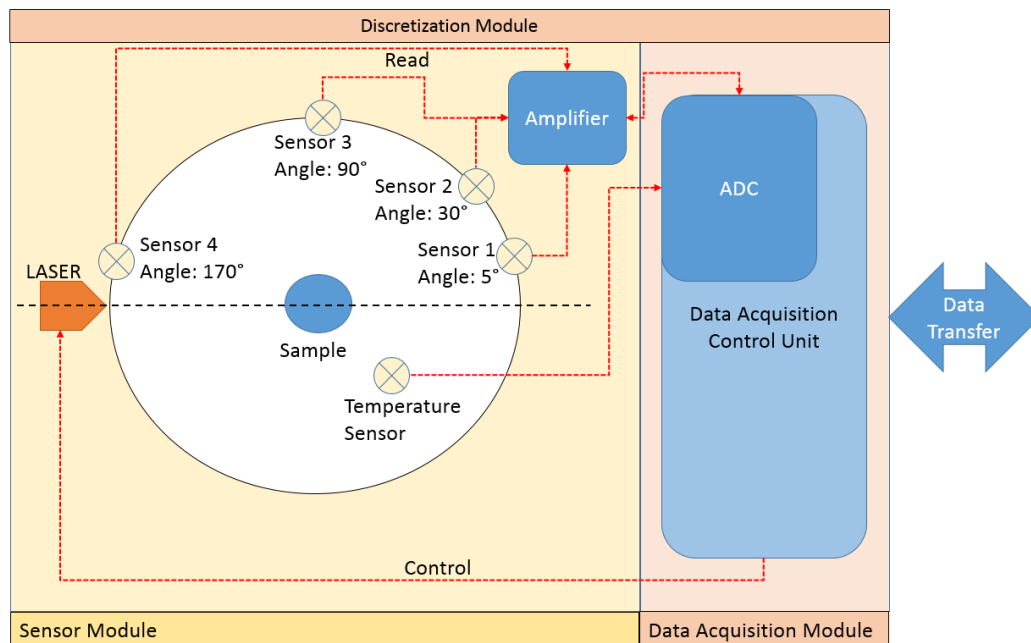


Figura 7. Schema conceptului pentru modulele senzor, respectiv achiziție de date

discretizare, senzor + achiziție de date.

Datorită faptului că temperatura joacă un rol major, influențând atât intensitatea luminii împrăștiată cât și frecvența de roll-off, am decis să proiectăm sistemul astfel încât să existe, de asemenea, un senzor de temperatură. Senzorul poate oferi informație asupra temperaturii din camera întunecată. Citirea temperaturii se poate face la cerere de către modulul de calcul. Modulul de calcul poate utiliza această valoare pentru a efectua unele corecții asupra valorilor estimate pentru dimensiunea particulelor

Camera în care este plasată proba trebuie să fie complet închisă pentru a evita orice zgomot generat de lumina mediului. În plus, pereții camerei trebuie să fie vopsiți într-o culoare care absoarbe lumina, astfel încât să nu existe reflexii parazite.

Algoritmul de calcul al modului va decide care e senzorul optim de citire în funcție de mai mulți factori. În cazul în care prima citire relevă o intensitate prea mică a luminii, sistemul va citi un senzor la un unghi mai mic. Toate deciziile sunt luate la nivelul platformei de calcul. Platforma de achiziție de date oferă funcționalitatea software-ului de a citi un

senzor selectabil pentru lungimea seriei și o frecvență configurabile. Ceea ce este important este ca semnalul să reprezinte cu mare precizie fluctuațiile de lumină care rezultă.

Intrarea pentru modulul de conversie analog-digital este semnalul analogic de tensiune. Folosind un convertor analog-digital acest modul generează o serie de numere. Aceste numere sunt stocate în memoria dispozitivului sau pot fi transferate spre modulul de calcul. Pentru acest modul există diverse opțiuni posibile: integrarea de pe piață a unui modul de achiziție a datelor, implementarea unui modul propriu de achiziție de date sau adaptarea unui sistem existent pentru a lucra ca un modul de achiziție a datelor. Am investigat caracteristicile unui modul de achiziție de date și am analizat în detaliu opțiunea de a implementa un astfel de sistem de date propriu.

Modulul de calcul procesează seriile de timp digitale, realizează diverse operații matematice și computaționale și oferă informații despre dimensiunile particulelor. Modulul de calcul controlează, de asemenea, sistemul de achiziție de date. Și aici avem mai multe opțiuni. Am investigat și pus în aplicare următoarele opțiuni:

- o implementare Matlab a unui modul de calcul, care rulează pe un PC,
- o implementare Java care rulează pe un dispozitiv Android (smartphone, tabletă),
- o implementare Python care rulează pe o mică platformă de calcul Linux (de exemplu, un Raspberry Pi cu ecran sau fără)
- o implementare javascript + html care rulează într-un browser, pe un PC sau pe un smartphone, sau orice alt dispozitiv cu acces la un browser.

4. DEZVOLTAREA ALGORITMULUI PENTRU PROCESAREA DLS

Algoritmul propus de noi permite o mare flexibilitate, ceea ce în final conduce la o portabilitate maximă a acestei soluții.

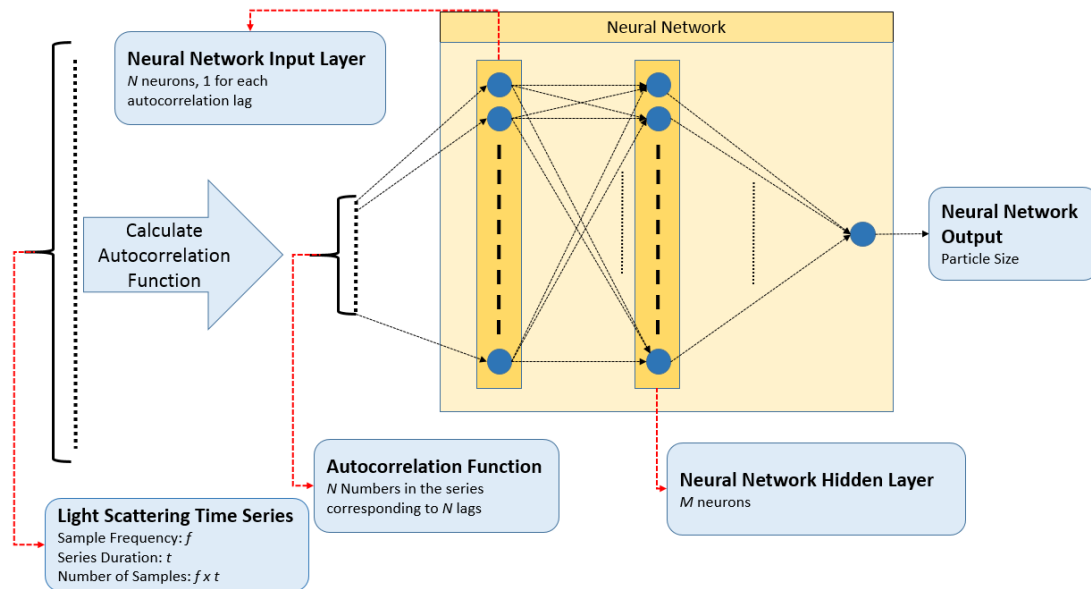


Figura 8. Abordarea DLS asistata de o rețea neuronală artificială

Nucleul modului de calcul este algoritmul asistat de o rețea neurală artificială, algoritmul care va fi folosit intens de către utilizatorul final. Ca intrare pentru rețea avem o serie de timp. Aceasta, pe baza ponderilor, funcțiilor de transfer și a arhitecturii sale, va oferi ca ieșire dimensiunea estimată a particulelor. Figura 8 prezintă o imagine de ansamblu a algoritmului de estimare. Într-o primă etapă este calculată numeric funcția de autocorelație cu un număr preselectat de întârzieri. Apoi, fiecare dintre valorile din sirul de autocorelație obținut este trimisă către un neuron din stratul de intrare: prima valoare la primul neuron, a doua la al doilea și așa mai departe, dar de fiecare dată aceeași ordine de întârziere la același neuron. Rețeaua neurală artificială va oferi ca ieșire diametrul mediu hidrodinamic estimat al particulelor.

Acest algoritm este implementată în dispozitivul minaturizat în modulul de calcul, împreună cu o parte de suport care are scopul de a gestiona sistemul de achiziție de date. Această parte de suport și de management de achiziție oferă funcționalitatea de condiționare a semnalului seriei de timp oferit ca intrare în rețeaua neurală, dar, de asemenea, gestionează în mod dinamic comportamentul sistemului de achiziție de date. Ideea principală a acestei părți de suport este de a furniza citiri corecte precum și serii de timp pregătite în mod

corespunzător pentru rețeaua neurală artificială. Pentru că dorim masuratori ale unei game largi de tipuri de particule aflate atât în aer cât și în apă, și pentru că lumina împrăștiată variază foarte mult în caracteristici în aceste intervale țintă, atât în intensitate cât și în spectrul de frecvență, trebuie să reducem variațiile pentru seturi diferite la intrarea rețelei. De

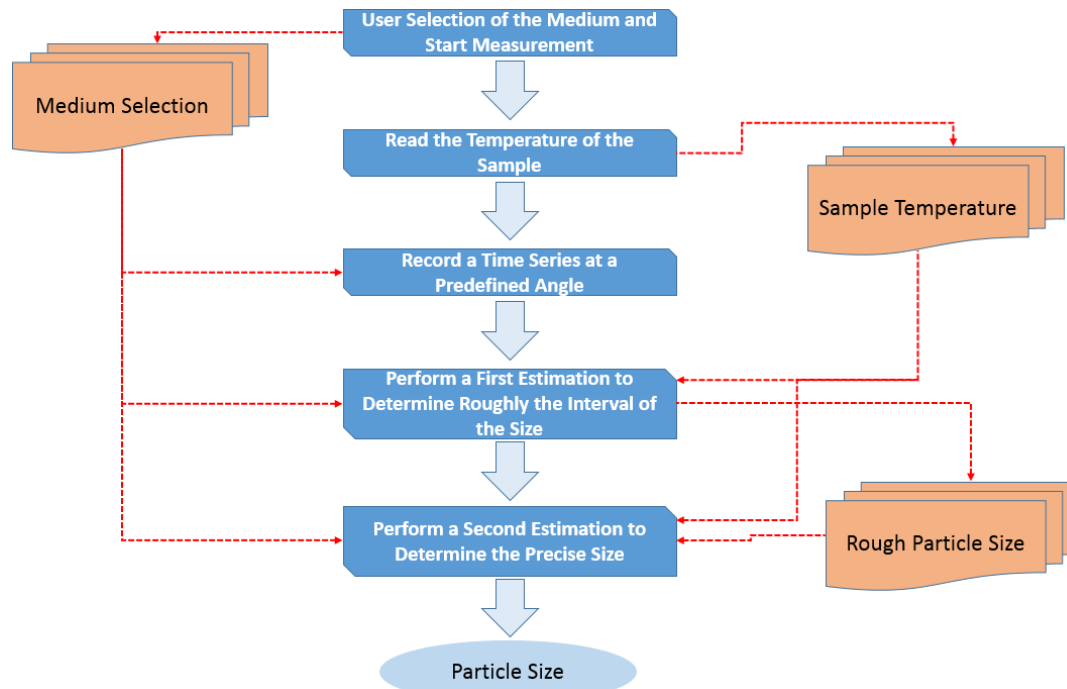


Figura 9. Algoritm de gestionare a achizitiei de date

asemenea, pentru anumite combinații de dimensiuni medii de particule trebuie să utilizăm unghiuri de măsurare diferite. De exemplu, măsurătorile pentru particule aflate în lichid, la un unghi mai mic de 30 de grade, când lumina sursă este de 633 nm, nu sunt posibile, în timp ce pe de altă parte pentru particule aflate în aer, avem nevoie de unghiuri mai mici de 30 de grade pentru a măsura particule cu același tip de lumină. De asemenea, chiar și pentru același mediu, ar putea fi avantajos să selectăm un unghi mai mic sau mai mare în funcție de intervalul de dimensiune în care se află particulele măsurate. Când avem un unghi mic intensitățile sunt mai mari, permițând măsurarea luminii împrăștiată de particule mai mici, dar pentru particule în apă, de exemplu, avem și frecvențele din spectru mai apropiate una de alta pentru dimensiuni diferite, ceea ce face să fie mai greu de deosebit valoarea dimensiunii pentru particule de mărimi apropiate. Și mai mult, putem implementa un mecanism de plauzibilitate prin măsurarea la 2 unghiuri diferite, în același timp, și transmiterea datelor către două rețele paralele, efectuând verificarea încrucișată a răspunsului pentru a constata dacă răspunsul este corect.

Acesta este motivul pentru care am proiectat modulul de senzor cu 4 senzori, ceea ce duce la nevoia de a pune în aplicare o strategie inteligentă pentru citirea acestora, astfel încât să

putem obține precizia maximă a rețelei neurale artificiale. Algoritmului de control este implementat după cum urmează. În primul rând utilizatorul selectează un mediu, apă sau aer, apoi solicită o măsurătoare prin intermediul interfeței. Modulul de calcul va solicita o citire a temperaturii și va stoca valoarea primită pentru o utilizare ulterioară. Apoi, modulul de calcul va solicita o înregistrare a seriei de timp de la unul dintre senzorii. Selecția senzorului și prin urmare a unghiului de măsurare este legată de selecția mediului. Această primă citire a senzorului are scopul de a oferi date pentru ca sistemul să evalueze aproximativ în care o parte a intervalului de mărime se află dimensiunea particulelor. Cu această serie de timp o primă rețea neurală artificială, diferită pentru diferite medii, va estima dimensiunea aproximativă. Citirea temperaturii poate de asemenea fi folosită ca intrare.

În funcție de plasarea mărimii particulelor în intervalul de funcționare, modulul de calcul va solicita o citire suplimentară a unei serii de timp pentru o determinare mai precisă. Din nou, va fi selectat unghiul cel mai potrivit în funcție de dimensiunea medie a particulelor în intervalul de funcționare. Seriile de timp înregistrate vor fi procesate cu o altă rețea neurală, specializată pentru acel unghi și interval. Pentru o mai bună precizie am putea avea zeci de rețele neurale implementate. De exemplu pentru o gamă de dimensiuni de 1-1000 nm am putea avea 10 rețele neurale pentru fiecare unghi, fiecare dintre ele pentru o gamă diferită: 1-100, 100-200, 900-1000 nm. Acest lucru ar permite o determinare mai precisă cu rețeaua care este specializată pentru aceste condiții. Rețeaua neurală artificială generală e pregătită pentru întreaga gama de dimensiuni și funcționează ca un prim evaluator grosier.

Interfața om-mașină depinde de alegerea modulului de calcul. Acesta poate fi interfata standard de Matlab (pentru punerea în aplicare Matlab a platformei de calcul) sau poate fi o aplicație Android, o pagină web sau o interfață cu touchscreen (pentru platforma de calcul independentă Raspberry Pi).

Soluția propusă poate rula în următoarele variante:

- Un PC care rulează Matlab, cu o placa de sunet (sau o placa de sunet USB) utilizată ca modul de achiziție a datelor și cu modulul senzor conectat la aceasta
- Un PC care rulează Matlab, cu senzor conectat la propriul sistem de achiziție de date conectat la portul USB al PC-ului
- Un dispozitiv mic, de sine stătător, cu touchscreen, care conține toate modulele într-un singur

- Un dispozitiv mic, independent, pentru colectarea și stocarea datelor, care poate fi ulterior conectat la portul USB al PC-ului pentru descărcarea de date și analiză
- Sistemul de achiziție de date conectat la portul USB al PC-ului pentru calcul într-o pagină web
- Senzorul și sistemul de achiziție de date conectate prin bluetooth fie la un smartphone, tabletă sau PC, fiecare cu o aplicație ce permite calculul rezultatelor.

5. REZULTATE PRELIMINARE ȘI TESTE

Am efectuat o analiză detaliată privind modul în care ar trebui să fie proiectat și construit modulul de achiziție de date precum și platforma de calcul. Ca rezultat al acestei analize putem concluziona că, din punctul de vedere al intensității luminii împrastiate, putem măsura particule în intervalul 5-1500 nm, cu o configurație adecvată a sistemului. Din lista de parametri care afectează intensitatea luminii împrăștiate putem controla: unghiul de împrăstiere, intensitatea luminii, lungimea de undă a luminii sursă, distanța dintre senzor și volumul de împrăstiere, și, uneori, putem controla concentrația probei. O problemă majoră specifică unui sistem miniaturizat este de a detecta micile variații de intensitate pentru intervalul de dimensiuni ales. Pentru a rezolva această problemă putem apela la următoarele soluții:

- Folosirea unui unghi de împrăstiere mic. Această soluție este utilă dacă ne interesează doar intensitatea luminii însă trebuie să fim atenți și la influența unghiului de împrăstiere asupra frecvenței de roll-off în spectru, după cum se vede în analiza detaliată din teză. Pentru particule în apă, un unghi de împrăstiere mic nu este optim în toate situațiile.
- Folosirea unei distanțe mici între senzor și probă.
- Creșterea intensității luminii inițiale prin utilizarea unui laser de mare putere: aceasta ar trebui să fie, de asemenea, utilizat cu grijă, deoarece puterea laserului afectează în mod direct temperatura probei. Cu cât puterea laserului e mai mare, cu atât mai mare e creșterea temperaturii induse în probă. Temperatura, așa cum am văzut, afectează atât intensitatea luminii prin indicele de refracție, cât și frecvența de roll-off, ceea ce va conduce la măsurători foarte imprecise. În mod ideal, laserul

ar trebui să fie de putere cât mai mică, astfel încât efectele de încălzire să fie reduse la minimum. Problema studierii efectelor termice ale laserului asupra soluțiilor de nanoparticule a fost deja abordată în mai multe lucrări, cum ar fi [148] [149] [150] [151] și nu a reprezentat subiectul de studiu al acestei lucrări.

- Folosirea unei lungimi de undă mică a luminii: acest parametru afectează de asemenea frecvența de roll-off. Cu toate acestea acest parametru nu va fi reglabil în sistemul final pentru că aceasta ar însemna să avem mai multe tipuri de laser, ceea ce este impractic pentru un dispozitiv care se dorește a fi relativ ieftin.
- Creșterea concentrației particulelor: în funcție de condițiile de măsurătoare uneori poate fi posibil să ajustăm concentrația însă deseori acest lucru nu e posibil. De exemplu, pentru măsurători în timp real pe teren, pentru particulele din aer, va fi dificil să se adapteze concentrația. De cele mai multe ori singura opțiune e scaderea concentrației prin diluare.
- O idee suplimentară pentru a mări intervalul de dimensiune este de a utiliza un senzor analogic și a amplifica semnalul de la senzor cu un amplificator performant. Desigur, acest lucru poate funcționa numai dacă senzorul este încă în măsură să detecteze variații mici de lumină.

Nici una dintre aceste reguli pot fi însă aplicate fără o mare atenție, pentru că, așa cum putem vedea la analiza detaliată a dependențelor între parametri, aceștia au o influență asupra altor parametri cheie și nu doar asupra intensității luminii împrăștiate. Chiar și influența asupra intensității luminii împrăștiate este destul de complexă.

Am constatat că este realist să ne propunem următoarele limite pentru propriul nostru sistem proiectat:

- Mediu: aer. Interval: 5-1000 nm
- Mediu: apa. Interval: 50 - 1500 nm

Pentru a realiza intervalele propuse, trebuie să folosim o combinație inteligentă de parametri, într-un mod dinamic, pentru a putea evalua intervalul selectat de dimensiuni ale particulelor atât pentru apă cât și pentru aer. Figura 10 prezintă imaginea generală a dependențelor dintre parametrii fizici și parametrii de performanță ale sistemului de achiziție

de

date.

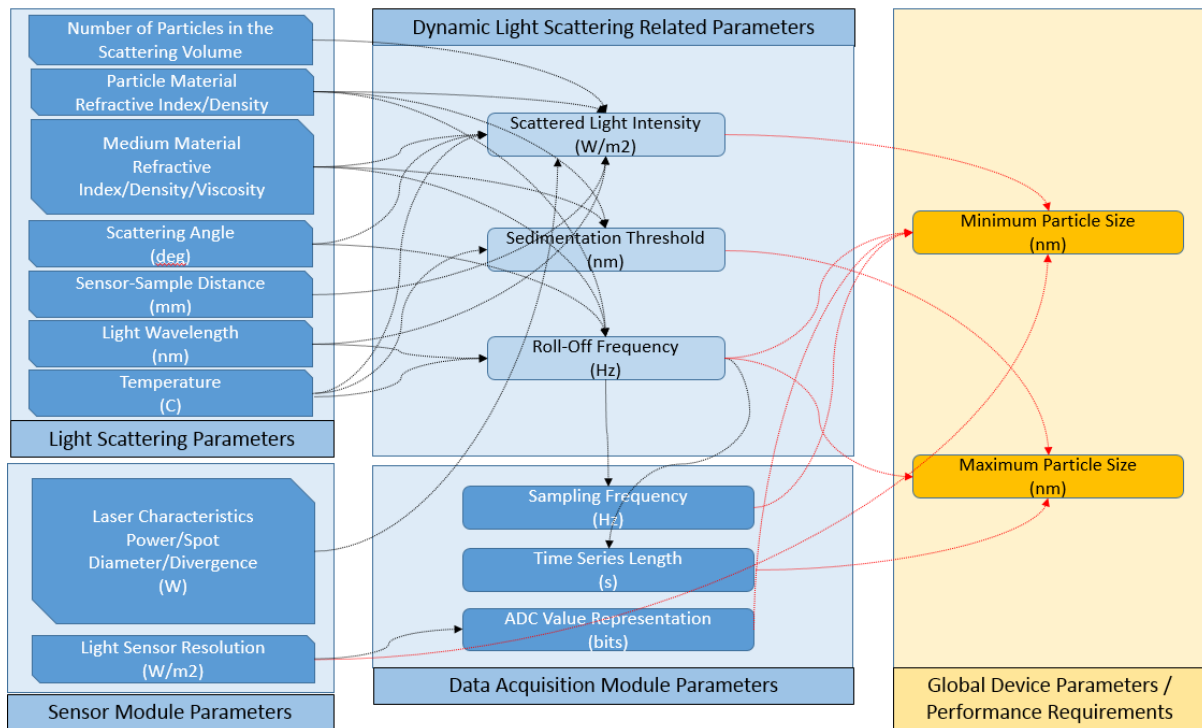


Figura 10. Dependențele între parametrii senzorii, cei ai sistemului de achiziție și cei fizici precum și cei de performanță generală a dispozitivului

Deoarece interacțiunile sunt destul de complexe nu putem stabili o valoare optimă pentru fiecare parametru. Am efectuat analize detaliate cu privire la impactul fiecăruia dintre acești parametri pe sistemul nostru. Unul dintre scopurile acestui exercițiu a fost de a afla mai întâi dacă este posibil și realist să proiectăm un sistem pentru mediul și intervalul de dimensiuni vizat. În urma analizei considerăm că este posibil. Un alt scop a fost de a vizualiza și identifica conexiunile între parametri. Rezultate detaliate sunt descrise în teza asociată acestui rezumat.

Un sumar al principalei parametri ai sistemului de achiziție a datelor e prezentat în Tabel 1.

Parametru de achiziție de date			Parametru globali al dispozitivului		
Frecvența de achiziție (Hz)	Lungimea seriei de timp (secunde)	Reprezentarea ADC (biți)	Dimensiunea minimă a particulelor (nm)	Dimensiunea maximă a particulelor (nm)	Mediu
16,000	4	16	50	1500	Apă
16,000	4	16	5	1000	Aer

Tabel 1. Parametrii dispozitivului

După o trecere în revistă a obiectivelor și fundamentelor teoretice pentru procesarea semnalelor, am identificat parametrii fizici cheie care influențează proiectarea sistemului. Am investigat fiecare parametru în detaliu și am evaluat care ar trebui să fie performanța țintă a sistemului nostru de achiziție. Am ajuns la următoarele cerințe de performanță:

- Dimensiunea particulei:
 - In apa: 50 - 1500 nm
 - In aer: 5-1000 nm
- Frecvența de achiziție: 16,000 Hz
- Timpul de achiziție: 2 secunde
- Unghi de achiziție: 5, 30, 90, 175 de grade
- Putere laser: 0.05-10 W
- Rezoluție senzor: 0,001 W / m²

De asemenea, am ajuns la concluzia că nu există o soluție universală unică, prin urmare, trebuie să proiectăm un sistem flexibil, capabil de a fi configurat.

Dupa analiza anterioară am executat teste și simulări în urma cărora am stabilit că vom folosi o rețea neurală de tip $MX100-n-1$ (unde M e un număr întreg) cu algoritm de învățare cu gradient conjugat Fletcher-Power. Aceasta este însă doar o indicație aproximativă privind configurația rețelei deoarece configurația reală a acesteia trebuie să fie bine reglată și selectată pentru a fi optimă pentru problema care trebuie rezolvată. Pentru testele efectuate mai departe am folosit următoarele tipuri de serii de timp pentru instruirea rețelei neurale:

- Dimensiunea particulei: 1-1-1000 nm, unghiul de împrăștiere: 4 °, lungimea de undă: 532 nm, temperatură: 20C, frecvența de eșantionare: 16 kHz, lungimea seriei de timp: 2s
- Dimensiunea particulei: 1-1-1500 nm, unghiul de împrăștiere: 90 °, lungimea de undă: 633 nm, temperatură: 20 ° C, frecvența de eșantionare: 16 kHz, lungimea seriei de timp: 2s

Mai departe vom descrie pe scurt modul în care am generat seriile de timp folosite la instruirea rețelei neurale artificiale. Pentru a utiliza o rețea neurală artificială pentru rezolvarea unei probleme particulare, structura acesteia trebuie să fie adaptată pentru respectiva problemă [178], [270]. Adaptarea, care are loc prin ”învățare”, necesită cantități mari de date care constau în paradigma învățării supervizate în seturi de intrări cu ieșiri cunoscute. Seriile de timp brute nu pot fi folosite la intrarea unei rețele, deoarece acestea pot avea lungimi diferite și pot arăta total diferit în raport cu alte serii produse de aceiași centri de împrăștiere. Studiul prezentat în [276] descrie utilizarea unei rețele neurale artificiale instruite folosind spectrul de frecvență al intensității luminii dispersate, cunoscut sub numele de spectru de putere, iar detaliile nu vor fi repetate aici. În această lucrare vom folosi autocorelația seriilor de timp, care are aceeași formă unică pentru centrii de împrăștiere cu un anumit diametru, indiferent de lungimea seriilor de timp, atâta timp cât această lungime e mai mare decât o valoare minimă.

Utilizarea seriilor experimentale pentru procesul de învățare nu este o soluție utilă deoarece bilele tipice de latex, folosite în a pregăti o suspensie calibrată, au o anumită eroare în fabricarea lor pentru o diametru particular. Mai mult, acestea nu pot fi fabricate cu o precizie suficient de bună cu un pas diametru de 1 nm, pas folosit de noi pentru seriile de învățare.

Alternativa folosită de noi este de a genera serii de timp DLS simulate, având diametru, frecvență, unghi de împrăștiere și număr de măsurători pe serie cunoscut. Algoritmul de generare a seriilor de timp folosit este o variantă îmbunătățită a algoritmului utilizat în [276]. Transformata Fourier rapidă [101], [280] poate fi folosită pentru a calcula valoarea absolută a spectrului de frecvență al seriilor de timp, cunoscut sub numele de spectru de putere (PS). Putem compara spectrul calculat din datele experimentale cu spectrul teoretic așteptat. Spectrul teoretic este descris de funcția Lorentz $S(f)$ (2) [7], [281], funcție folosită în metoda de referință.

O provocare pe care am întâlnit-o în această etapă a fost de a simula comportamentul unui sistem stocastic, reflectat în seria de timp produsă de lumină coerentă împrăștiată de suspensie, folosind o procedură complet deterministă. O procedură simplă constă în însumarea unor funcții armonice, cum ar fi sinus sau cosinus, având frecvențe și amplitudini diferite, la momente diferite, pentru a compune seriile de timp. Ecuația (20) descrie suma:

$$x(t) = \sum_{i=1}^{N_f} A(f_i) \cdot \sin(2\pi f_i t + \varphi_i) \quad (20)$$

În (20), $A(f_i)$ este amplitudinea componentei de index i , f_i este frecvența componentei de index i , φ_i este faza inițială a componentei de index i , t este timpul și N_f este numărul de frecvențe folosite în generarea seriilor de timp. Coeficientul a_0 este selectat pentru a fi o valoare fixă, de ordinul zecilor, aceeași pentru toate seriile, în timp ce a_1 este calculat din ecuația (3) pentru fiecare diametru al particulelor. Termenul $A(f_i)$ a fost selectat ca fiind rădăcina pătrată a lui $S(f_i)$ calculat cu ecuația (2).

Toate fazele inițiale φ_i au fost generate folosind numere aleatoare cu distribuție uniformă în intervalul $[0, 2\pi]$. Valorile f_i sunt generate ca fiind distanțate egal în intervalul $[0, f_s/2]$, unde f_s este rata de eșantionare a sistemului de achiziție de date. Motivul pentru care nu am generat frecvențe mai mari de $f_s/2$ este explicat de teorema Whittaker-Nyquist-Kotelnikov-Shannon [58. 282. 283. 284. 285], teoremă care e formulată în versiunea Shannon astfel: „Dacă funcția $x(t)$ nu conține frecvențe mai mari decât f hertz, ea este complet determinată printr-o serie de puncta pe ordonată distanțate la $1/(2f)$ secunde“ [101. 280]. Mai mult decât atât, după ce o serie de timp este înregistrată sau generată cu rata de eșantionare f_s , transformata Fourier rapidă va produce un spectru de frecvență în intervalul $[0, f_s]$, spectru simetric față de $f_s/2$ [101. 280]. Amplitudinea $A(f_i)$ a componentei de index i este determinată folosind rădăcina pătrată a $S(f_i)$.

Pentru o mai bună utilizare a resurselor de calcul în timpul procesului de generare a datelor pentru învățare, am investigat influența numărului de frecvențe N_f și a numărului N_t de date conținute în seriile de timp, asupra preciziei de evaluare a diametrului a rețelei rezultate. Am ajuns la concluzia că cel mai bun rezultat pentru generarea unei serii de timp cu $N_t=2^n$ se obține atunci când seria de timp este generată folosind un număr minim de $N_f=2^{n-1} + 1$ frecvențe. De asemenea, seriile de timp care pot fi utilizate în învățarea ANN ar trebui să aibă un număr de date $N_t=2^n$ unde n trebuie să fie de minim 13. Pentru o serie de timp având $N_t=2^n$, ar trebui să fie utilizate un număr de frecvențe $N_f > 2^{2n-1} + 1$, pentru a obține un diametru cât mai precis.

Pentru a rezolva problema de determinare a dimensiunii particulelor cu o ANN am folosit un model de învățare supravegheat. Vom descrie mai jos mai detaliat pașii efectuați pentru învățarea ANN.

În primul pas am generat un set de serii de timp pentru diametre selectate. Am selectat $n = 15$, prin urmare, fiecare serie de timp a avut 32768 de puncte de date și un număr de 16385 frecvențe. Gama de diametre a fost de 10 - 1200 nm, cu 20 de serii de timp pentru fiecare diametru. Pasul pentru creșterea diametrului a fost de 1 nm. Pentru generarea fazelor φ_i ale fiecărei componente armonice am folosit numere aleatoare cu distribuție uniformă în $[0 - 2\pi]$, care au asigurat că seriile generate pentru același diametru nu sunt identice, corespunzând unor diametre ușor diferite la estimarea prin procedura DLS de referință. Unghiul folosit a fost de 90° iar frecvența de achiziție 16000 Hz.

Mai mult, deoarece rețeaua de energie electrică funcționează la 50 Hz, am adăugat zgomot la seriile de timp generate, zgomot constând într-o sumă de funcții sinus, ca în ecuația (20), având frecvențe de tip $50 \cdot i$, i fiind un număr natural în intervalul $1 - i_{\max}$. i_{\max} este frecvența de eșantionare împărțită la 50, adică frecvența maximă a armonicei 50 Hz care este mai mică decât f_s . Amplitudinile armonicilor au scăzut exponențial cu numărul armonicilor, ca în ecuația (21), unde A_{ts} este amplitudinea seriilor de timp, evaluate ca fiind diferența dintre valoarea maximă și valoarea minimă din seriile de timp, iar i este numărul armonicilor. Fazele inițiale ale armonicilor φ_i au fost generate folosind numere aleatoare cu distribuție uniformă în $[0, 2\pi]$. Seriile zgomot x_h au fost calculate separat de seriile de timp și a adăugate la acestea la final.

$$x_h(t) = \sum_{i=1}^{i_{\max}} 0.03 \cdot A_{ts} \cdot \exp(-0.25 \cdot i) \cdot \sin(2\pi f_i t + \varphi_i) \quad (21)$$

În afara zgomotului de 50 Hz am adăugat și zgomot aleator. Seriile de zgomot aleator, x_n , au fost calculate și ele separat de seriile de timp, folosind ecuația (22), unde N_{rnd} este numărul de frecvențe f_i generate folosind numere aleatoare cu distribuție uniformă în intervalul $[1 - f_s]$. Pentru seriile generate am folosit valoarea de 300 pentru N_{rnd} .

$$x_n(t) = \sum_{i=1}^{N_{\text{rnd}}} 0.01 \cdot A_{ts} \cdot \exp(-0.005 \cdot i) \cdot \sin(2\pi f_i t + \varphi_i) \quad (22)$$

După calcularea seriilor cu zgomot, acestea au fost adăugate la seriile de timp generate. Valorile particulare ale coeficienților în ecuațiile (21) și (22) au fost selectate în urma unui proces de încercare și eroare, comparând spectrul de frecvență al seriilor de timp generate cu spectrul de frecvență al seriilor de timp DLS înregistrate experimental. Trebuie să menționăm că această caracteristică de a adăuga zgomot în datele utilizate pentru instruirea

rețelei neurale artificiale este esențială pentru producerea unei rețele care poate evalua corect serii de timp experimentale deoarece acestea conțin de asemenea zgomot.

Al doilea pas constă în calcularea autocorelației fiecărei serii. Acest lucru a fost realizat cu ajutorul unei funcții implementate în din Matlab. Autocorelația a fiecărei serii de timp a fost calculată cu 350 de întârzieri pe serie iar apoi rezultatele au fost încărcate într-o matrice cu 350 de linii în coloanele acesteia, având tot atâtea coloane cât am avut serii de timp. Valorile țintă au fost diametrele calculate pentru fiecare serie de timp folosind procedura DLS de referință. Figura 11 ilustrează autocorelarea pentru trei serii de timp calculate cu zgomot adăugat, așa cum este descris mai sus, pentru diametre de 100, 700 și 1200 nm.

Examinând Figura 11 observăm efectul zgomotului adăugat ca o distorsiune de la forma ideală exponențială a scăderii autocorelării. Distorsiunea este evidentă pe autocorelația seriilor de timp generate pentru diametre mai mici, pentru care valorile se apropie de axa întârzierilor mai repede decât valorile pentru seriile corespunzând diametrelor mai mari.




Figura 11. Autocorelația pentru trei serii de timp calculate cu zgomot adăugat, pentru diametre de 100 nm, linia continuă albastră, 700 nm linie punctată roșie, și 1200 nm, linia cu puncte negre

Pentru generarea și formarea rețelei neurale artificiale am utilizat pachetul Matlab. Rețeaua folosită a fost de tip fitare, cu trei straturi, așa cum am descris anterior. Primul strat, de intrare, a avut 350 neuroni, stratul ascuns a avut 26 de neuroni iar al treilea, de ieșire, a avut un neuron, deoarece ieșirea reprezintă diametrul mediu al particulelor. Algoritmul de învățare folosit a fost algoritmul Levenberg-Marquard [286]. Învățarea s-a oprit după 58 de iterații, deoarece valoarea coeficientului de regresie R a atins 1. Învățarea a durat 38 de minute pe un laptop cu un procesor Intel I7 7300. 70% din seturile de date au fost utilizate pentru învățare, 15% pentru testare și 15% pentru validare.

La sfârșitul procesului de formare a fost generată o funcție Matlab având salvate în cod matricile cu ponderile rețelei, ceea ce face rețeaua obținută să fie portabilă pe alte platforme, cum ar fi Octave și în același timp permite o portare ușoară în alte limbaje de programare.

Pentru a calcula diametrele folosind această funcție a fost calculată autocorelația cu 350 întârzieri pentru fiecare serie de timp care a fost apoi plasată într-o matrice sub forma unei coloane. Rularea funcției implică înmulțiri și adunări între matrici, operațiune mai puțin intensă decât operațiunea de fitare a unei funcții folosind o procedura de minimizare neliniară pentru χ^2 , procedură care implică un număr mare de evaluări ale funcției de fitat.

După implementare, algoritmul și abordarea propusă a fost testată în detaliu, atât pe date




Figura 12. Erorile relative față de diametrul de referință

simulate cât și experimentale. Vom analiza pe scurt câteva dintre rezultatele obținute.

În prim pas, am testat abordarea folosind datele simulate. Abordarea asistată de o rețea neurală artificială a fost testată pe datele simulate folosite în procesul de învățare, mai precis

pe întregul set de date generat, nu numai pe 70% din datele alese pentru învățare. Diametrele care au fost utilizate ca ținte au fost calculate prin metoda DLS de referință. Am numit aceste diametre diametre de referință, d_{ref} . Aceste diametre de referință au fost comparate cu diametrele calculate cu metoda asistată neuronal, denumit în continuare diametrele NN, d_{NN} . Graficul diametrelor d_{NN} versus diametrele de referință va avea forma unei linii drepte, prin urmare, nu îl vom prezenta aici. Mai relevantă însă este o analiză a erorilor relative, err , exprimate în%, definite de ecuația (23).

$$err = \frac{d_{NN} - d_{ref}}{d_{ref}} \cdot 100(\%) \quad (23)$$

Un grafic al erorilor relative față de diametrul de referință este prezentat în Figura 12.

Figura 12 relevă că erorile relative sunt mai mari în intervalul de diametre mai mici de




Figura 13. Erorile relative față de diametrul de referință – intervalul de diametre mici

500 nm și sunt neglijabile pentru diametre mai mari decât această valoare. Privind mai atent, observăm că erorile sunt destul de mari pentru valorile foarte mici ale diametrelor. O posibilă explicație este legată de zgomotul adăugat în datele generate, zgomot care denaturează autocorelația seriilor de timp generate pentru diametre mici mult mai mult decât pentru seriile de timp generat pentru diametre mai mari. Marind zona de diametre mici din Figura 12 vom obține Figura 13. Observăm că pentru diametre mai mari de 40 nm, eroarea relativă este mai mică de 3% și scade rapid cu diametrul, prin urmare, putem concluziona că abordarea asistată neuronal pentru procesarea seriilor de timp DLS este corectă pentru diametre în intervalul [40-1200] nm.

6. REZULTATE EXPERIMENTALE ȘI REZULTATE DE PERFORMANȚĂ

Următorul set de teste efectuat a fost pe date experimentale. Pentru procedura DLS de referință am folosit un set de date măsurat pe probe care conțin drojdie. Pentru abordarea asistată neuronal am folosit trei seturi de date: argilă, lapte (proteine) și apă reziduală.

Primul set de date experimentale a fost supus procedurii de referință care evaluează mărimea particulelor printr-o fitare neliniară cu cele mai mici pătrate și nu prin abordarea cu rețele neurale artificiale. Scopul acestui test este de a prezenta un exemplu care ilustrează procedura de referință și metoda DLS în general, folosind date experimentale.

Pentru a obține suspensia de particule am dizolvat în apă o cantitate mică solidă de drojdie (*Saccharomyces cerevisiae*). De asemenea, am preparat o soluție concentrată de zahăr brun (greutate 15% în apă). Am adăugat suspensie de drojdie cu volum de 0,2 cm³ la 3,5 cm³ de sirop și plasată într-o cuvă în calea unui fascicul laser (632 nm). Temperatura probei a fost




Figura 14. Datele referitoare la funcția de autocorelație (punctată) și fitarea exponențială neliniară pentru seria a 175-a de timp înregistrată (dimensiunea estimată a particulelor 2209.2 nm)

de 20 de grade C. Am monitorizat și înregistrat intensitatea luminii, rezultând serii de timp cu o durată de 8 secunde. Am înregistrat serii de timp la fiecare 0,5 ore timp de aproximativ 160 ore, adică aproximativ 1 săptămână.

Am estimată dimensiunea medie a celulelor de drojdie a utilizând procedura DLS de referință. Figura 14 și Figura 15 arată scăderea autocorelării și rezultatul fitării prin metoda celor mai mici pătrate neliniară pentru două măsurători distincte din timpul înregistrării de 1 săptămână. Putem observa în exemplele oferite că fitarea prin algoritmul ne-liniar este destul de bună. De asemenea, se pot vedea în exemplele oferite dimensiunile particulelor estimate




Figura 15. Datele referitoare la funcția de autocorelație (punctată) și fitarea exponențială neliniară pentru seria de timp cu indexul 185 (mărimea estimată a particulelor 2030.1 nm)

folosind metoda de referință.

Figura 16 prezintă evoluția dimensiunii medii a celulei de drojdie timp de 1 săptămână. Putem observa că, în primele zile are loc o creștere a dimensiunii particulelor, de la aproximativ 600-700 nm până la un maxim de aproximativ 2600-2700 nm. Apoi dimensiunea medie a celulelor de drojdie începe să scadă lent pentru perioada rămasă. O posibilă explicație a acestei evoluții este următoarea: în primele 3 zile celulele de drojdie sunt în creștere deoarece acestea se pot hrăni cu soluția de zahăr în care au fost plasate. Atunci

când soluția de zahăr se epuizează, celulele de drojdie se opresc din creștere și încep să moară. Scăderea în mărime este cauzată de dezintegrarea celulelor de drojdie și moartea lor.

Se poate observa, de asemenea, că dimensiunea estimată pentru celulele de drojdie este în concordanță cu dimensiunile bacteriilor și drojdiei: 1000-5000 nm [291].




Figura 16. Dimensiunea estimată pentru celulele de drojdie pe durata măsurătorii de aproximativ 1 săptămână

Rezultatele arată că metoda de referință, și deci metoda DLS, permite evaluarea diametrelor celulelor biologice precum și monitorizarea dinamicii proceselor care afectează diametrelor, cum ar fi creșterea celulară, diviziunea celulelor, moartea celulelor, etc. Dimensiunea celulelor de drojdie și dinamica procesului de fermentație, ca exemplu, poate fi monitorizată cu succes cu această metodă. Metoda poate fi folosită în general pentru a monitoriza variația dimensiunilor particulelor pentru diverse suspensii.

După testarea metodei asistate neuronal cu serii de timp DLS pentru centrii monodisperși, am testat această abordare pe date înregistrate în timpul experimentelor de tip DLS. Primul tip de suspensie utilizată a fost compusă din particule de argilă arsă, măcinate manual și plasate într-un tub transparent. Măcinarea într-un mojar produce particule sferice cu o distribuție largă de diametre. Înaintea începerii înregistrării seriilor de timp DLS, am lăsat suspensia să se sedimenteze timp de 4 ore, pentru a ne asigura că particulele rămase au diametrul în intervalul de ordinal sutelor de nanometri.

Ca o consecință a rezultantei nulă a trei forțe: gravitație, forță dinamică și forța

sedimentare se desfășoară cu o viteză constantă, v_s , care, pentru o particulă de formă sferică este de forma:

$$v_s = \frac{2(\rho - \rho_0)g}{9\eta} \cdot r^2 \quad (24)$$

unde r este raza sferei, ρ este densitatea materialului centrelor de împrăștiere, ρ_0 este densitatea fluidului iar η este coeficientul de viscozitate dinamică a fluidului. Mai multe detalii cu privire la rolul sedimentării și a mișcării browniene în fluctuațiile unei serii de timp DLS pot fi găsite în [104].

Observăm din ecuația (24) că viteza de sedimentare crește cu pătratul razei particulelor, ceea ce face ca particulele mai mari să se sedimenteze mai repede. Ca urmare a acestei proceduri de sedimentare, prin reglarea distanței de la partea superioară a soluției la raza laser ca fiind egală cu 1 mm, într-un experiment de lungă durată de ordinul zilelor, putem selecta suspensiile care au particule mai mici decât o anumită valoare. Variația diametrului celor mai mari particule rămase în suspensie față de timpul de sedimentare este prezentată în Fig. 1 din referința [276], figură pe care nu o vom reproduce aici. Trebuie să menționăm că această procedură bazată pe sedimentare nu este precisă în ceea ce privește filtrarea particulelor după diametrul lor, pur și simplu pentru că distanța de 1 mm nu poate fi măsurată cu o precizie foarte bună deoarece forțele superficiale creează o suprafață concavă la partea superioară a fluidului în contact cu aerul. Aceeași serie de timp înregistrată a fost procesată însă în ambele moduri, folosind metoda de referință DLS cât și metoda alternativă asistată neuronal, prin urmare, precizia metodei de sedimentare nu este atât de importantă. Metoda de sedimentare descrisă aici trebuie privită doar ca un procedeu de preparare a probei care asigură faptul că particulele din fasciculul au diametre într-un interval relativ mic, cu valori mai mici decât un anumit diametru.

Pentru măsurătorile particulelor de argilă am preparat suspensii de diferite diametre medii prin măcinarea manuală de lut ars într-un mojar pentru durate diferite. Măcinarea a fost uscată la început și a durat 10 minute iar apoi a fost urmată de încă 25 de minute după adăugarea unei mici cantități de apă deionizată. Am extras o cantitate mică de amestec pe care am diluat-o cu apă deionizată pentru a atinge un grad bun de transparență după care am plasat amestecul într-un tub cilindric transparent și sigilat. Fluidul purtător a fost apă la 20 ° C. Densitatea de argilă arsă a fost de 1362 kg / m³, densitatea apei 1000 kg / m³, $\eta = 1.002$ mPa·s.

Diametrele calculate cu funcția asistată neuronal sunt denumite în continuare diametrele ANN. Figura 17 ilustrează variația diametrelor particulelor în zona activă a tubului de probă și anume zona care se află în calea fasciculul laser, în funcție de timp (măsurat de la începutul înregistrării).




Figura 17. Diametrele de referință (cercuri) și diametrele ANN (stele) în funcție de timp

Am observat că există o foarte bună corelare a diametrelor calculate cu cele două metode. De fapt, dependența liniară $d_{NN} = a * d_{reff} + b$ are un coeficient de corelație liniară [287. 288], $R = 0,9998$. Observăm că erorile cresc în timp odată cu scăderea diametrului efectiv mediu, ceea ce este în concordanță cu concluzia secțiunilor anterioare care descriu erorile pentru seriile de timp simulat.

Se poate observa de asemenea că diametrul este în scădere, ceea ce este în concordanță cu procesul fizic care are loc în suspensie, mai precis procesul de sedimentare.

A doua suspensie utilizată în testarea metodei a conținut proteine din lapte. 30 ml de lapte degresat cu 1,5% grăsime a fost centrifugat la 3000 rpm timp de 10 minute, iar conținutul de proteine a fost extras din fundul vasului și depozitat folosind un balon de plastic la 0,4 °C. Înaintea experimentului DLS proba a fost diluată în apă deionizată până când aceasta a devenit transparentă pentru fasciculul laser, având o culoare albastruie în lumină albă. În acest scop, 0,05 ml de proteine din lapte separat așa cum este descris mai sus a fost diluat în 3,45 ml de apă deionizată. Agregarea proteinelor din lapte a fost indusă cu lactat de calciu, în forma sa cea mai comună de pentahidrat $C_6H_{10}CaO_6 \cdot 5H_2O$. Pentru a pregăti agentul de agregare, 0,0333 g de lactat de calciu a fost dizolvat în 20 ml apă deionizată, făcând astfel o soluție de 0,1665% (masă). Un volum de 0.5 ml de astfel de soluție a fost

injectat în 3,5 ml de suspensie apoasă de proteină după care a fost indusă agregarea proteinelor. Au fost înregistrate serii de timp cu durată de 8 s fiecare și cu timpul de întârziere între ele de 172 s. Diametrul mediu a fost evaluat atât folosind metoda DLS de referință cât și metoda nouă bazată pe o rețea neurală artificială.

Probele au fost bazate pe lapte de vacă, lapte care conține aproximativ 30-35 grame de proteine pe litru. Cele mai multe dintre proteine (80%) sunt reprezentate de caseină, care poate fi găsită sub formă de micelle de caseină, care sunt agregate formate din mai multe mii de molecule de proteine. A fost măsurată deja dimensiunea proteinelor din suspensie de lapte de vacă iar rezultatele sunt raportate în lucrări cum ar fi [289, 290] iar rezultatele raportate indică faptul că cele mai multe dintre proteine au un diametru cuprins în intervalul 77-115 nm [289] sau ceva mai mare în [290], însă procedeul de preparare a implicat pentru îndepărtarea particulelor de grăsime procesul de filtrare mai degrabă decât cel centrifugare. Noi am folosit centrifugarea iar probele au fost extrase din fundul recipientului. Am găsit un diametru de




Figura 18. Variația diametrelor proteinelor în timpul agregării. Cercurile sunt diametrele de referință și triunghiurile sunt diametrele ANN

referință de 118 nm, în acord foarte bun cu [289] și [290].

Figura 18 ilustrează variația diametrelor centrilor de împrăștiere, calculate atât folosind metoda de referință DLS cât și metoda DLS asistată neuronal. Momentul 0 de timp a fost selectat pentru a fi momentul imediat înaintea injectării agentului de agregare.

Figura 18 relevă că agregarea proteinelor din lapte este destul de rapidă, astfel că în aproximativ 6 minute agregarea a atins un maxim al diametrului. Relevant însă pentru această lucrare este faptul că diametrele estimate de metoda asistată neuronal sunt apropiate de diametrele de referință, fiind ușor supraestimate. Această caracteristică poate fi regăsită și în Figura 17 pentru alt tip de suspensie.

Al treilea set de date experimentale utilizat a fost bazat pe măsurători pentru ape reziduale. Apa reziduală este apa care rezultă din utilizarea domestică (WC, baie, chiuvetă), fiind colectată în sistemul de canalizare. Aceasta este ghidată prin conducte către un centru de tratare a apei. Tratarea apei implică de obicei trei etape. Prima etapă este etapa de screening, care are scopul de a elimina obiectele mari din apa reziduală. Obiectele mari pot fi pietre, bețe, obiecte sanitare (scutece, bumbac, batiste) dar și sticle sau haine. Aceste obiecte mari pot bloca și deteriora echipamentul de tratare pentru următoarele etape. În aceeași etapă se îndepărtează nisipul. A doua etapă constă în tratamentul primar al apei, care implică separarea materialelor organice (deșeuri de obicei umane) solide din apa reziduală. În acest scop, apa uzată este plasată în rezervoare mari, pentru a permite solidelor să se scufunde. Solidele care se depun sunt numite și „nămol“. Aceste rezervoare sunt de obicei circulare și au un set de elemente răzuitoare care răzuiesc podeaua rezervoarelor pentru a muta nămolul spre centru, astfel încât nămolul să poată fi luat de pompe. În cea de-a treia etapă apa trece printr-un tratament secundar. În această etapă apa este plasată în bazine de aerare care sunt de obicei sub formă dreptunghiulară. Este pompat aer în apă, bacteriile fiind stimulate să consume materialul organic care a rămas după primele etape în apă. A patra etapă este cea în care apa este pusă din nou în rezervoare de decantare pentru a permite scufundarea noului nămol format ca urmare a acțiunii bacteriene. Procesul este apoi similar cu cel utilizat în etapa 2. Apa este lăsată să curgă peste un perete și este filtrată suplimentar prin nisip pentru a îndepărta alte substanțe nocive. Apa rezultată este apoi eliberată în natură. Uneori, în ultima etapă, apa este de asemenea tratată cu clor sau raze ultraviolete pentru a elimina bacteriile daunatoare.

Figura 19 prezintă o schemă a stației de tratare a apei care a fost utilizată pentru măsurătorile prezentate aici. Figura prezintă de asemenea punctele în care au fost luate

probele pentru măsurători. La punctul 1, a fost utilizată apa netratată pentru măsurătoare.




Figura 19. Schema stației de tratare a apei

Considerăm această măsurătoare ca măsurătoare de intrare a apei. La punctul 2, a fost folosită apa care a trecut prin nămolul activ și prin rezervorul de aerare. La punctul 3 a fost folosită apa care a trecut prin sedimentarea finală. Probele de apă din cele trei puncte menționate au fost supuse măsurătorilor pentru timp scurt (5 minute) și timp lung (10 ore). Pe durata scurtă au fost înregistrate serii de timp la fiecare 10 secunde. Pentru durata lungă au fost înregistrate



Figura 20. Diverse etape ale stației de tratare a apei

serii de timp la fiecare 20 de minute.

Figura 20 prezintă câteva imagini de la stația de epurare a apei utilizate pentru luarea probelor.

Rețeaua neurală artificială a fost ușor diferită de cele folosite anterior datorită intervalului larg de dimensiuni a particulelor pe care ne-am așteptat să le găsim în apă. Aceasta a avut un strat de intrare de 350 de neuroni, corespunzând celor 350 de întârzieri. Stratul ascuns a avut 26 de neuroni, iar stratul de ieșire a avut 1 neuron, oferind ca ieșire diametrul mediu pentru particulele găsite în apa tratată. Datele de instruire au constat din

seturi de serii de timp simulate, pentru intervalul de diametre 10-3000 nm, generate cu un pas de 1 nm, cu 20 de seturi pe diametru.

Figura 21 arată dimensiunea medie a particulelor estimată în timpul diferitelor etape de prelucrare a apelor uzate.




Figura 21. Diametrul mediu al particulelor în suspensie, măsurat în timpul diferitelor etape de prelucrare a apelor uzate

Apele reziduale de la intrare, colectate la poziția 1, conțin nisip, nămol și suspensii organice. Diametrul mediu estimat a fost de 4700 nm. Este demn de remarcat faptul că apa de intrare este deja pre-filtrată, astfel încât particulele mari sunt deja înlăturate. După sedimentare, numai particulele organice au rămas în rezervorul de aerare. După aproximativ 7 - 8 ore de timp petrecut în rezervorul de aerare cu bacterii aerobe, dimensiunea particulelor rămase a fost de aproximativ 660 nm. Acest lucru este vizibil în măsurătoarea de la locația 2. La locația 3, apa iese din rezervorul de sedimentare având particule mici de 550 nm.

Ce se poate observa este că, folosind un singur tip de măsurătoare fizică, de tip DLS, și monitorizând variația diametrului în timp, putem identifica tipul particulelor din suspensie. Vom prezenta mai jos câteva cazuri pe care le-am întâlnit în măsurătorile noastre.

Atunci când avem o tendință de scădere în dimensiune, avem doar particule anorganice, deoarece această evoluție este o caracteristică generală a procesului de sedimentare iar sedimentarea se întâmplă atunci când densitatea materialului particulelor este mai mare decât densitatea apei, cum se întâmplă în cazul particulelor anorganice.

Atunci când particulele sunt organice, densitatea particulelor este comparabilă cu densitatea de apă și particulele nu se scufunda. Când avem o tendință de creștere în dimensiune, putem deduce că avem particule organice, deoarece particulele organice tind să crească prin agregarea sau prin evoluție și creștere celulară.

Cu toate acestea, atunci când avem o dimensiune descrescătoare, urmată de valori oscilante și apoi de valori constante mari, avem un amestec de suspensii anorganice și organice. Acesta este rezultatul faptului că mărimea raportată de algoritm este dimensiunea particulelor predominante, cu toate particularitățile menționate ale acestui fenomen, de exemplu, particule mai mari având un impact mai mare asupra măsurătorii, așa cum se vede în secțiunile fundamentale teoretice. Scăderea inițială este cauzată de sedimentarea particulelor anorganice, iar creșterea este cauzată de faptul că vor avea impact asupra valorii măsurate doar particulele organice mari, inițial în număr mai mic decât sedimentele, dar acum singurele rămase în suspensie.





Figura 22. Monitorizarea dimensiunii particulelor la punctul de măsurare 1. Măsurătoare de durată scurtă.


Figura 22 arată evoluția dimensiunii la locația 1 pentru măsurătoarea pentru timp scurt



de 300 de secunde.

Figura 23. Monitorizarea dimensiunii particulelor la punctul de măsurare 1. Măsurătoare de durată lungă

Măsurători pentru aceeași locație, dar de data aceasta pentru o perioadă mai lungă de 10 ore



sunt prezentate în Figura 23.

Figura 24. Monitorizarea dimensiunii particulelor la punctul de măsurare 2. Măsurătoare de durată scurtă.

Figura 25 prezintă rezultatele monitorizării dimensiunii la locația 2, rezervorul de aerare.




Figura 25. Monitorizarea dimensiunii particulelor la punctul de măsurare 1. Măsurătoare de durată lungă.

Figura prezintă și o fitare liniară care arată o tendință generală scădere dimensiune, corespunzând liniei descrise de ecuația $y = -0.065x + 370$, $R^2 = 0.095$.

Figura 26 prezintă variația dimensiunii pentru măsurătorile la locația 3, locația de ieșire.

La locația 1, monitorizarea pe durată scurtă prezintă o sedimentare rapidă a particulelor anorganice care domină inițial măsurătoarea deoarece acestea sunt în număr mult mai mare. De îndată ce numărul lor scade, particulele organice, care nu se scufunda deoarece au o densitate egală cu densitatea apei, încep să domine măsurătoarea. Acesta este motivul pentru saltul de la valoarea scăzută a dimensiunii particulelor la o valoare mai mare după aproximativ 150 de secunde. În monitorizarea de durată mai mare la locația 1 putem observa că particulele organice rămân în apă, ceea ce are sens, deoarece apa nu a suferit încă etapele tratamentului menite să reducă conținutul organic.

La locația 2, monitorizarea pe durată scurtă arată că încă mai există particule anorganice care domină măsurarea, cel mai probabil particule care nu au fost filtrate și au fost agitate în apă datorită mișcării prin rezervoare. În monitorizarea de durată mai mare se poate observa că

aceste particule sedimentează și dimensiunea tinde să scadă încet. Acest lucru este în concordanță cu etapa de tratament care presupune amestecarea apei cu nămol activ, care are




Figura 26. Monitorizarea dimensiunii la punctul 3. Timp de măsurare scurt.

particule mici și bacterii în concentrație mai mare.

La locația 3, ieșirea, există o cantitate de particule mai mică, dar cu un amestec de mărimi în domeniul dimensiunilor scăzute. Evoluția dimensiunii poate fi explicată observând că măsurarea are loc pentru a particulele din volumul de împrăștiere, în calea razei laser. Rezultatul este în concordanță cu particule care sunt organice, dar au o densitate puțin mai mică decât apa. Odată cu trecerea timpului, particulele plutesc spre suprafață, cu cât e mai mare diametru, cu atât mai mare viteză. Particulele mai mici plutesc în derivă, de asemenea, dar cu o viteză mai mică. În final, unele particule organice rămân în apele uzate după prelucrare.

Sumarizând rezultatele pentru cele trei seturi de date experimentale prezentate (lut, lapte, apa reziduală) putem observa că în timp ce procesul de sedimentare acționează ca un procedeu de filtrare, agregarea proteinelor nu face acest lucru, așa încât, odată ce agregarea a început, polidispersia este mai mare. Am selectat acest tip de suspensie pentru a testa robustețea procedurii asistate neuronal. Mult mai grăitor este însă un grafic al erorilor relative ale procedurii asistate neuronal în comparație cu rezultatele obținute prin metoda referință. Erorile, definite ca în ecuația 9, sunt prezentate în Figura 27 pentru cele două tipuri de suspensii, preparate prin sedimentare și agregare.

Figura 27 relevă faptul că erorile relative ale procedurii asistate neuronal sunt mai mari pentru probele cu proteine agregate decât pentru probele cu sedimentare, însă erorile sunt destul de mici pentru ambele cazuri. Erorile mai mari sunt cauzate de distribuția mai largă a dimensiunilor în cazul agregării. Procedura propusă de noi s-a dovedit a fi destul de




Figura 27. Plot erorilor relative ale RNA comparativ cu referința pentru cele două tipuri de suspensii, argilă și lapte, preparate prin sedimentare și agregare

precisă în calculul diametrului mediu al particulelor în suspensie, fiind considerabil mai rapidă decât metoda de referință DLS. Întregul set de 30 de serii de timp înregistrate pe proba de argilă sedimentată a fost prelucrat cu metoda de referință DLS de referință după calcularea spectrului de putere în 0.12846 s. Procedura DLS pe baza rețelei neurale a durat 0.000019 s după ce autocorelația seriilor a fost calculate. Așadar procedura DLS asistată neuronal este de 6761 de ori mai rapidă.

Concluzia este ca procedura DLS asistată de o rețea neurală artificială este rapidă și poate fi implementată pe platforme de calcul ușoare. O metodă fizică simplă, de tip DLS, poate fi utilizată în monitorizarea mărimii particulelor în suspensie în apele reziduale. Variația dimensiunii particulelor pe timp scurt poate furniza și informații cu privire la tipul de

particule în suspensie, fără utilizarea unei proceduri chimice, a reactivilor sau a altor tipuri de materiale consumabile.

7. IMPLEMENTARE ALTERNATIVĂ A UNEI REȚELE NEURALE ARTIFICIALE PENTRU MĂSURĂTORI DLS

După obținerea rezultatelor prezentate în secțiunile anterioare cu implementarea bazată pe Matlab, ne-am propus să optimizăm abordarea pentru a testa limitele preciziei pe care le putem obține cu o rețea neurală artificială.

Am considerat că o implementare proprie a unei rețele într-un limbaj de programare ne-ar permite o flexibilitate mai mare decât cea oferită de setul de instrumente Matlab, ceea ce ar crește posibilitățile de a optimiza abordarea. Pentru implementarea acesteia am selectat limbajul de programare Python [292], datorită avantajelor sale inerente, și anume fiind ușor de învățat, având un suport excelent și o multitudine de biblioteci deja disponibile. Pentru implementare am folosit bibliotecile open source TensorFlow [293], Theano [294] și Keras [295].

Pentru implementarea Python am ales o strategie diferită de cea folosită în Matlab. În implementarea Matlab am folosit o arhitectură fixă a rețelei, aleasă la început și păstrată pentru întreaga funcționare a sa. În implementarea Python ne-am dorit să experimentăm diferite arhitecturi.

TensorFlow este o bibliotecă flexibilă care permite dezvoltarea de algoritmi de calcul într-o paradigmă bazată pe tensori. Este o bibliotecă utilizată în multe domenii științifice, care are un bun nivel de suport pentru inteligență artificială, inclusiv pentru rețele neurale [293].

Theano este o bibliotecă Python utilizată pentru a realiza operații cu matrici cu mai multe dimensiuni, sau pentru calcule numerice [294].

Keras este o bibliotecă scrisă în Python care interacționează cu TensorFlow și Theano. Aceasta este de obicei folosită pentru programare de nivel înalt a rețelelor neurale [295].

Folosirea acestor trei biblioteci ne permite să definim și să implementăm propria noastră rețea într-un mod flexibil, controlând toți parametrii acesteia. În acest fel, design-ul poate evolua treptat până la performanța optimă. În primii pași am căutat strategia optimă de învățare dar și arhitectura optimă a rețelei neurale, inclusiv numărul optim de straturi, neuroni, funcțiile de activare și algoritmul de învățare. După multe încercări am automatizat procesul

prin implementarea a diferite scripturi Python care variază într-un mod inteligent parametrii cheie ai rețelei pentru a găsi optimul.

După cum se poate observa în secțiunile anterioare, arhitectura poate avea un impact mare asupra calității rezultatelor obținute. În prima etapă am încercat diferite arhitecturi bazate pe o structură cu 100-600 neuroni în stratul de intrare, un strat ascuns cu neuroni care variază între 5 și 100 și un strat de ieșire cu un neuron. Ca funcții de activare am căutat funcția optimă pentru stratul ascuns, folosind următoarele funcții în spațiul de căutare [296]: rectified linear unit, hyperbolic tangent, sigmoid, softmax, linear activation function. În primele noastre încercări am folosit aceeași funcție de activare și în stratul de ieșire, dar în timpul cercetării noastre am constatat că o rețea cu una dintre funcțiile de mai sus în stratul ascuns, dar cu funcția de activare liniară în stratul de ieșire este cea mai bună alegere.

Pentru algoritmul de învățare, am căutat, de asemenea, în întreg spațiul oferit de biblioteca keras [297]. În urma etapei de căutare am constatat că algoritmul optim pentru problema noastră este algoritmul Adam [298. 299].

În pasul următor am dezvoltat cod Python care a variază numărul de neuroni de intrare și numărul de neuroni din stratul ascuns, și, de asemenea, variază funcțiile de activare și algoritmii de învățare, verificând pentru fiecare iterație performanța rețelei formate pe date experimentale. Toate rețelele care au avut o eroare medie mai mare decât un prag, definită în cercetarea noastră ca 10% într-o primă etapă, apoi 5% într-o a doua etapă, au fost abandonate, toate celelalte au fost salvate.

În căutarea noastră pentru cele mai bune rețele neurale pentru a rezolva problema DLS am dezvoltat arhitectura mai departe și am căutat configurația optimă atunci când rețeaua neurală are două straturi ascunse și nu doar unul. Am automatizat căutarea în spațiul funcțiilor de activare, algoritmilor de învățare și al dimensiunilor straturilor obținând o configurație optima, pe care am folosit-o mai departe pentru a obține rezultatele experimentale prezentate în secțiunea următoare:

- Dimensiunea stratului de intrare (neuroni): 350
- Dimensiunea primului strat ascuns (neuroni): 26
- Dimensiunea celui de-al doilea strat ascuns (neuroni): 10
- Dimensiunea stratului de ieșire (neuroni): 1
- Numărul de epoci de formare: 40000
- Algoritm de învățare: adam
- Rata de învățare: 0,001

- Funcții de activare:
 - Strat ascuns 1: softmax
 - Strat ascuns 2: rectified linear unit
 - Strat de ieșire: liniar
- Indicator de performanță monitorizat: eroarea medie procentuală absolută (MAPE)

Pentru instruirea rețelei am folosit serii de timp generate urmând aceeași abordare descrisă anterior, pentru particule în intervalul 50-400 nm, cu 20 serii de timp pentru fiecare valoare, cu zgomot indus de 50Hz și armonicile.

După formarea rețelei am folosit pentru validarea ei datele experimentale pe particule de argilă, același set de date ca și cel utilizat pentru testarea implementării MATLAB.

Ca urmare a acestei abordari am ajuns la următoarele concluzii:

- Cu acest tip de rețea, pe datele experimentale, se poate obține o performanță acceptabilă. O eroare relativă pe setul de instruire de aproximativ 8,5% pentru seed fix (=7) pentru generatorul de numere aleatoare și una de aproximativ 6% pentru seed aleator a fost observată.
- Pentru o performanță optimă pe date experimentale, performanța generală a rețelei nu va fi optimă. Acest lucru înseamnă că, atunci când rețeaua va fi bine datele experimentale, nu va face același lucru pentru un interval mai larg de dimensiuni. Când seedul folosit pentru numerele aleatoare initiale ale configurației rețelei a fost randomizat, performanța rețelei a fost de fiecare dată diferită.
- Pentru seriile generate, în mod evident, cea mai bună performanță este obținută atunci când setul de date folosit la învățare și testare au fost identice
- Rețelele au avut o performanță mai bună dacă seriile generate folosite la învățare au fost injectate cu zgomot, așa cum am descris anterior.

În continuare, am încercat diverse combinații între seriile de învățare și arhitecturile posibile, pe modele de test similare cu cele din pasul anterior. Pentru o alegere a seriilor de învățare / arhitectură, am construit un număr fix de rețele neurale. Am păstrat rețeaua cu cea mai mică eroare obținută. Am repetat iterativ acest proces pentru diferite combinații arhitectură / serii de învățare. În finalul acestei etape am comparat rezultatele pentru optimele găsite.

În pasul următor am folosit rezultatele obținute până în prezent pentru a testa rețeaua optima găsită. După 4409 de cicluri de formare, aceasta a atins o performanță optimă. Mărimea lotului pentru ciclul de învățare a fost 7820. Performanța pentru etapa de instruire este descrisă prin următorii indicatori: eroare în validare a fost de 0,66% iar eroarea în testare




Figura 29. Evoluția erorii rețelei pe durata etapei de formare a rețelei

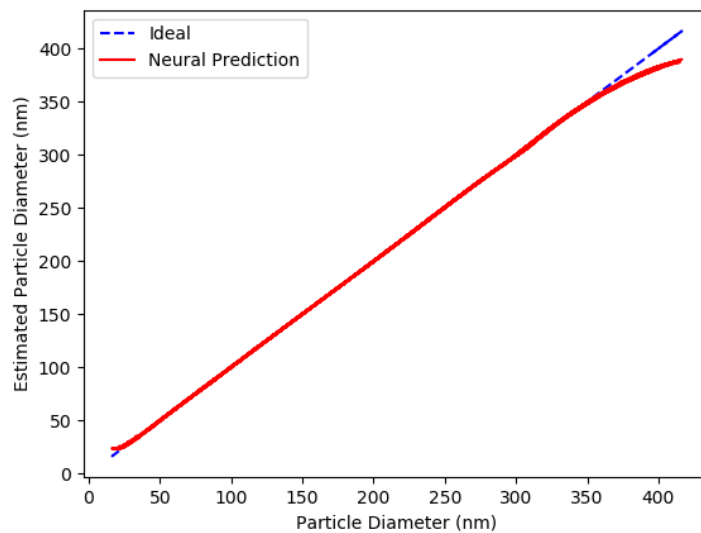


Figura 28. Diametrul particulelor estimat pentru întregul set de date generate folosit pentru învățare (interval 20-400 nm)

(pe serii de timp simulat) a fost de 2,12%.

După ce rețeaua a fost instruită am estimat mărimea particulelor pentru setul de date de particule de argilă. Eroarea abordării asistate neuronal în raport cu abordarea de referință a avut o valoare foarte bună de 0.197%.

Figura 28 prezinta evolutia erorii relative în timpul instruirii. Putem observa că rețeaua converge spre performanțe optime și atinge optimul după 4409 cicluri.

Figura 29 prezinta diametrul particulelor estimat de abordarea asistată neuronal rezultată. Putem observa că, în intervalul 50-350 nm diametrele se potrivesc perfect cu cele de referință. La extreme, și anume la valori de aproximativ 20-30 nm și peste 350 nm, rețeaua nu face o estimare perfectă, ceea ce duce la eroarea de validare menționată de aproximativ 2,2%. Cu toate acestea, în cazul în care intervalul generat acoperă intervalul în care este planificată folosirea rețelei, aceasta poate funcționa aproape perfect. Acest lucru înseamnă că dacă dorim să folosim o rețea pentru un anumit interval de dimensiuni, vom genera seriile de timp de învățare pentru un interval mai mare, care îl include pe cel în care rețeaua este planificată să funcționeze.

Figura 30 prezintă dimensiunea estimate de rețea pentru setul de date pe particule de argilă. Cu linie punctată verde am reprezentat mărimea particulelor de așteptat simulate pe baza unui model de sedimentare. Cu albastru am reprezentat dimensiunea estimată cu abordarea de referință Lorentz. Linia verde deschis și linia roșie reprezintă estimarea cu metoda de referință DLS și respective estimarea cu metoda asistată neuronal. Putem observa mai întâi că toate metodele urmează tendința unui model de sedimentare, ceea ce arată că măsurătorile și estimările sunt corecte calitativ. De asemenea, se poate observa că valorile

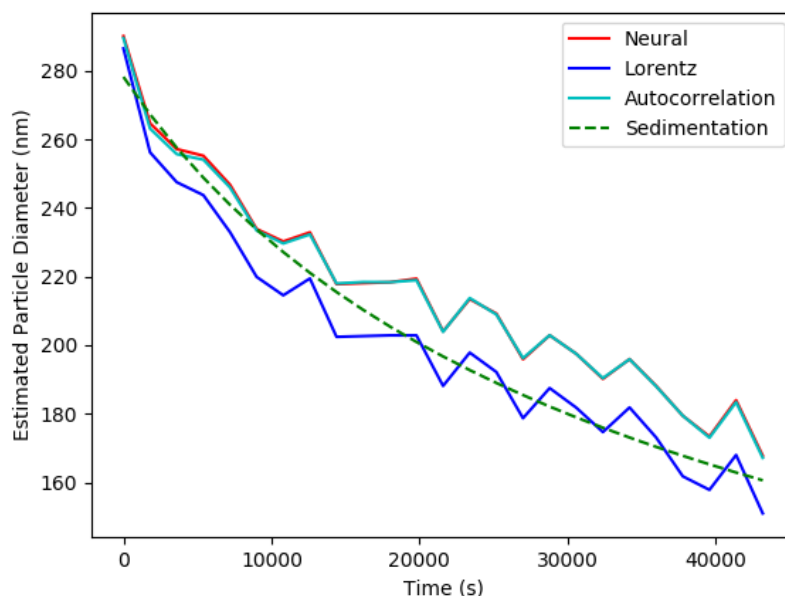


Figura 30. Estimarea dimensiunii particulelor prin metodele de referință și prin metoda asistată neuronal, alături de modelul teoretic de sedimentare

oferite de rețea și cele oferite de metoda referință sunt foarte apropiate unele de altele, fapt ce poate fi observat și în valoarea scăzută a erorii relative a rețelei, respectiv 0,19%. Metoda

propusă este, prin urmare, o modalitate de succes și precisă pentru a estima dimensiunile particulelor, cu toate avantajele prezentate.

8. IDEI ADIȚIONALE DE DEZVOLTARE

Abordarea prezentată în această lucrare se concentrează pe obținerea dimensiunii medii a particulelor. De cele mai multe ori, o suspensie conține un sistem polidispers de particule. Așa cum am văzut în secțiunile cu rezultate experimentale, obținerea dimensiunii medii a particulelor este de mare folos deoarece permite o analiză inteligentă a suspensiei. Un posibil următor pas ar o extindere a abordării propuse de noi, astfel încât ieșirea algoritmului să fie distribuția dimensiunii și nu numai dimensiunea medie. În teza asociată acestui rezumat sunt deja prezentate idei teoretice și rezultate ale unor simulări pe calculator cu privire la modul în care acest lucru ar putea fi realizat, dar activitatea experimentală și practică pentru extinderea la sisteme multidisperse este un următor pas, necesar pentru a pune în practică aceste idei.

9. CONCLUZII

În această lucrare am investigat posibilitatea îmbunătățirii metodelor bazate pe metodele bazate pe împrăștierea dinamică a luminii pentru evaluarea dimensiunilor nano și micro particulelor pentru particulele găsite în fluide lichide sau gazoase. Viziunea a fost de a construi în viitorul apropiat un dispozitiv portabil miniaturizat capabil să furnizeze aceste evaluări. Obiectivul principal a fost de a implementa o nouă procedură de estimare a dimensiunii particulelor utilizând măsurători de împrăștiere dinamică a luminii asistate de o rețea neurală artificială. Procedura ar trebui să fie mai simplă decât metodele existente și ar permite o un timp de calcul mai scurt, ceea ce ar duce la dezvoltarea viziunii menționate, și anume echipamentul miniaturizat. Ca obiectiv secundar ne-am propus să prezentăm idei pentru o configurație simplă pentru realizarea condiționării semnalului și conversia la o serie de timp digitală pentru un experiment dinamic de împrăștiere a luminii, dar prezentarea rezultatelor investigațiilor privind modul de integrare a procedurii într-un dispozitiv miniaturizat.

Având în vedere aceste obiective, am realizat următoarele:

- O scurtă trecere în revistă a metodelor bazate pe dispersia luminii dinamice existente și o analiză a limitărilor pe care le au acestea

- O scurtă analiză a diferitelor aspecte teoretice și practice legate de prelucrarea semnalelor, achiziția de date și rețelele neurale artificiale
- O investigație bazată pe rezultate obținute în simulări dezvoltate de noi, asupra conexiunilor și dependențelor dintre diferiții parametri fizici și parametrii de performanță ai dispozitivului miniaturizat
- Un design detaliat de la arhitectură la implementarea hardware și software a diferitelor module necesare pentru dispozitivul miniaturizat
- Implementarea unei proceduri noi care folosește o abordare bazată pe împrăștierea dinamică a luminii asistată de rețele neurale artificiale
- O integrare a hardware-ului și a software-ului, precum și a algoritmului propus și o implementare a 5 variante constructive ale dispozitivului
- Un set complet de teste pe date simulate și experimentale pentru procedura propusă, care relevă performanța și precizia abordării noi propuse
- O optimizare a procedurii de difuzie a luminii dinamice asistată de o rețea neurală artificială, implementată cu cod propriu în limbajul de programare Python
- O analiză succintă dar valoroasă a etapelor de dezvoltare viitoare

Ideile prezentate în această lucrare pot fi dezvoltate în continuare pentru a pune în aplicare un dispozitiv miniaturizat care poate estima dimensiunile particulelor pe teren. Avantajele aduse de abordarea ANN ar permite timpi de calcul extrem de rapizi. Practic, rezultatul poate fi obținut instantaneu, în timp real. Învățarea ANN a durat mai puțin de o oră pe un laptop Ultrabook care este optimizat pentru consumul de energie și nu pentru calcul. Odată ce ANN este formată, aceasta poate fi folosită pentru a calcula diametrele medii ale unui set de date de intrare. Acest calcul este de mii de ori mai rapid decât fitarea unei funcții printr-o procedură neliniară prin cele mai mici pătrate, deoarece se reduce la operații între matrici mai degrabă decât calculul valorilor unor funcții și calculul numeric al gradientilor. Timpul precis poate varia în funcție de dimensiunea setului de date, dar ramane de mii de ori mai scurt.

Lucrarea prezentată aici este un proof-of-concept pentru utilizarea ANN pentru prelucrarea seriilor de timp DLS și un pas spre proiectarea unui dispozitiv DLS portabil mic, cu cost scăzut, care poate utiliza o platformă de calcul modestă, cum ar fi un telefon mobil sau o platformă de dezvoltare mai degrabă decât un PC sau laptop. De asemenea, această lucrare reprezintă un pas spre proiectarea unui dispozitiv foarte rapid, în timp real, pentru a evalua diametrul mediu al particulelor în suspensie. Aplicațiile unui astfel de dispozitiv pot fi găsite

În orice domeniu în care există micro și nanoparticule de interes, atât în cunoașterea dimensiunilor acestora, cât și în studierea dinamicii procesului în desfășurare, pornind de la științele mediului, științele medicale, inginerie și procese de producție, industria alimentară, industria auto și aerospațială, dar și științe fundamentale, cum ar fi fizica și chimia.

10. BIBLIOGRAFIE

1. B. Berne, R. Pecora – “Dynamic Light Scattering”, Dover Publications Inc., Mineola, New York, (2000).
2. D. Tong – “Electromagnetism”, University of Cambridge, Part IB and Part II of Mathematical Tripos, (2015).
3. http://www.edinformatics.com/math_science/electromagnetic_spectrum.htm
4. T.S. Evans – “Symmetry and Unification”, Theoretical Physics, Physics Department, Imperial College London, (2009)
5. D. Tong – “Quantum Field Theory”, University of Cambridge, Part III Mathematical Tripos, (2006).
6. B. J. Ackerson – “Selected Topics in Static and Dynamic Light Scattering”, Van’t Hoff Laboratory, University of Utrecht, The Netherlands, (1986).
7. Clark, Lunacek, Benedek – “A Study of Brownian Motion Using Light Scattering”. American Journal of Physics. 38, 575, (1970).
8. D. T. Gillespie – “The Mathematics of Brownian Motion and Johnson Noise”. American Journal of Physics. 64, 225, (1996).
9. D. T. Gillespie – “Fluctuation and Dissipation in Brownian Motion”, American Journal of Physics. 61, 1077, (1993).
10. R. DeSerio, S. Hagen – “Brownian Motion”, University of Florida, Department of Physics, (2015).
11. Dan Chicea, "Using CHODIN to simulate the dynamics of coherent light scattering on nanofluids", Proc. SPIE 7469, ROMOPTO 2009: Ninth Conference on Optics: Micro- to Nanophotonics II, 74690B (17 May 2010); doi: 10.1117/12.866768; <https://doi.org/10.1117/12.866768>
12. D. Arzenšek – “Dynamic Light Scattering and Application to Proteins in Solutions”, University of Ljubljana, Faculty of Mathematics and Physics, Ljubljana, (2010).
13. Y. Sun – “Different Particle Size Information Obtained from Static and Dynamic Laser Light Scattering”, Simon Fraser University, BC, Canada, (2004).
14. C. Urban – “Development of Fiber Optic Based Dynamic Light Scattering for a Characterisation of Turbid Suspensions”, Swiss Federal Institute of Technology Zuerich, PhD Dissertation, Zuerich (1999).
15. L. Oegendal – “Light Scattering Demystified – Theory and Practice”, University of Copenhagen, (2016).

16. K.-N. Liou – “A Complementary Theory of Light Scattering by Homogenous Spheres”, University of Utah, Dept. of Meteorology, Salt Lake City, Utah, (1977).
17. D. Chicea – “Coherent Light Scattering on Nanofluids: Computer Simulation Results”, Physics Department, ULBS, (2007).
18. D. E. Koppel – “Analysis of macromolecular polydispersity in intensity correlation spectroscopy: The method of cumulants.”, *The Journal of Chemical Physics*, 57:4814-4820, (1975).
19. T. Ursell – “Diffusion of Solid Particles Confined in a Viscous Fluid”, (2005).
20. <http://www.physics.nyu.edu/grierlab/methods/node11.html>
21. <https://www.dkfz.de/Macromol/research/dls.html>
22. B. J. Ackerson, N.A. Clark – “Dynamic Light Scattering At Low Rates of Shear”, *Journal de Physique* (1981), 929.
23. Zetasizer APS User Manual. December 2008. See <http://www.malvern.com>
24. J. H. Wen – “Dynamic Light Scattering: Principles, Measurements and Applications”, (2010).
25. Dynamic Light Scattering: An Introduction in 30 minutes. Technical Note (MRK656-01), (2010). See <http://www.malvern.com>
26. C. B. Bargeron – “Measurement of a Continuous Distribution of Spherical Particles by Intensity Correlation Spectroscopy: Analysis by Cumulants”, *J. Chem. Phys.*, 61:2134-2138, (1974).
27. J. C. Brown, P. N. Pusey, R. Dietz – “Photon Correlation Study of Polydisperse Samples of Polystyrene in Cyclohexane”, *J. Chem. Phys.*, 62:1136-1144, (1975).
28. B. J. Frisken – “Revisiting the Method of Cumulants for the Analysis of Dynamic Light Scattering”, *Data. Appl. Opt.*, 40:4087-4091, (2001).
29. F. R. Hallet, T. Craig, J. Marsh, B. Nickel – “Particle Size Analysis: Number Distributions by Dynamic Light Scattering”, *Canadian Journal of Spectroscopy*, 34:63-70, (1989).
30. W. Brown – “Dynamic Light Scattering: The Method and Some Applications”. Clarendon Press, Oxford, (1993).
31. P. N. Pusey, W. van Megen – “Detection of Small Polydispersities by Photon Correlation Spectroscopy”, *J. Chem. Phys.*, 80:3515-3520, (1984).
32. B. Chu – “Laser Light Scattering: Basic Principles and Practice”, Academic Press, New York, (1991).
33. H. C. Van De Hulst – “Light Scattering by Small Particles”, Dover Publications, New York, (1981).

34. K. S. Schmitz – “An Introduction to Dynamic Light Scattering by Macromolecules”, Academic Press, San Diego, (1990).
35. H. R. Haller, C. Destor, D. S. Cannell – “Photometer for Quasielastic and Classical Light Scattering”, Rev. Sci. Instrum. 54: 973-983, (1983).
36. P. R. Bevington, D. K. Robinson – “Data Reduction and Error Analysis for the Physical Sciences”, McGraw-Hill, (1992).
37. G. Arutyunov – “Classical Field Theory”, Inst. For Theoretical Physics and Spinoza Institute, Utrecht University, (2011).
38. D. Fleisch – “A Student’s Guide to Maxwell’s Equations”, Cambridge University Press, (2008).
39. Bo Thide – “Electromagnetic Field Theory”, 2nd Edition, Upsala, Sweden, (2011).
40. T. Yu – “Lagrangian Formulation of the Electromagnetic Field”, (2012).
41. D. J. Griffiths – “Introduction to Electrodynamics”, Prentice Hall, New Jersey, (1999).
42. L. D. Landau, E. M. Lifshitz – „Electrodynamics of Continuous Media”, 2nd Edition, Pergamon Press, (1960).
43. L. D. Landau, E. M. Lifshitz – „The Classical Theory of Fields”, 3rd Edition, Pergamon Press, (1971).
44. A. S. Kompaneys – “Theoretical Physics”, Foreign Languages Publishing House, Moscow, (1961).
45. B. de Wit – “Introduction to Quantum Field Theory”, Institute for Theoretical Physics, Utrecht University, (2008).
46. B. U. Felderhoff – „On the Propagation and Scattering of Light in Fluids”, Phys. in press, (1974).
47. J. D. Jackson – „Classical Electrodynamics”, Wiley, New York, (1965).
48. R. Feynman – “The Feynman Lectures on Physics”, Addison Wesley Longman, (1970).
49. A. Einstein – “Investigation on the Theory of Brownian Movement”, Republication of the original 1926 translation, Dover Publications, (1956).
50. “The Collected Papers of Albert Einstein, Vol. 2, The Swiss Years: Writing, 1900 – 1909”, Princeton University Press, (1989).
51. R. Pecora – “Dippler Sifts in Light Scattering from Pure Liquids and Polymer Solutions”, Journal of Chemical Physics: 40:1604, (1964).
52. J. Goodman – “Some Fundamental Properties of Speckle”, J. Opt. Soc. Am. 66: 1145-1150, (1976).

53. C. Urban, P.Schurtenberger – “Characterization of Turbid Colloidal Suspensions Using Light Scattering Techniques Combined with Cross – Correlation Methods”, *J. Colloid Interface Sci.* 207(1): 150 – 158, (1998).
54. I. Block, F. Scheffold – “Modulated 3D Cross – Correlation Light Scattering: Improving Turbid Sample Characterization”, *Rev. Sci. Instruments.* 81(12): 123107, (2010).
55. P. Hassan, S. Kulshreshtha – “Modification of the Cumulant Analysis of Polydispersity in Quasielastic Light Scattering Data”. *Journal of colloid and interface science*, 300(2): 744-8, (2006).
56. S. Provencher – “CONTIN: A General Purpose Constrained Regularization Program fro Inverting Noisy Linear Algebraic and Integral Equations”, *Computer Physics Communications*, 27(3): 229, (1982).
57. S. R. Aragon, R. Pecora – “Theory of Dynamic Light Scattering from Polydisperse Systems”, *The Journal of Chemical Physics*, 64:2395, (1976).
58. Shannon, C. “A Mathematical Theory of Communication”. *Bell System Technical Journal* 27 (3): 379-423.
59. Schneider, T.D. “Information Theory Primer”. National Cancer Institute, 14.04.2007.
60. Carter, T. “An Introduction to Information Theory and Entropy”, Santa Fe. 2014.
61. Massey, J. “Guessing and Entropy”. *Proc. IEEE International Symposium of Information Theory*, 2013
62. Malone, David; Sullivan, Wayne. “Guesswork is not a Substitute for Entropy”. *Proceedings of the Information Technology and Telecommunications Conference.* 2005.
63. National Instruments Low-Cost Data Acquisition Family. <http://www.ni.com/low-cost-daq/>
64. Rei, S. “Implementing A Low Cost Data Acquisition System for Engineering Education Programs in Universities”. *Proceedings of the BRCEBE – ICEBE 2017 Conference*, Sibiu, Romania.
65. Enzo Mastinu, Bo Håkansson, Max Ortiz-Catalan, “Low-cost, open source bioelectric signal acquisition system”, (2017), *Proc. Conference: 14th International Conference on Wearable and Implantable Body Sensor Networks*, At High Tech Campus - Eindhoven, THE NETHERLANDS
66. Teensy USB Development Board: <https://www.pjrc.com/store/teensy36.html>
67. Teensy USB Virtual Serial Receive Speed:
https://www.pjrc.com/teensy/benchmark_usb_serial_receive.html
68. Adafruit Development Boards, Teensy 3.6: <https://www.adafruit.com/product/3266>

69. Teensy 3.6 Pinout: <https://www.pjrc.com/teensy/pinout.html>
70. Mihiu, P. "Procesarea Numerica a Semnalelor", Editura Alma Mater, 2005.
71. Wikipedia: sine wave: https://en.wikipedia.org/wiki/Sine_wave
72. Euler, L. "Chapter 8: On transcending quantities arising from the circle of Introduction to the Analysis of the Infinite", page 214, section 138 (translation by Ian Bruce, pdf link from 17 century maths). (1748).
73. Fourier, Collins English Dictionary - Complete & Unabridged 10th Edition, HarperCollins, accessed 5 May 2017
74. Mit Open Courseware: Fourier Analysis: <https://ocw.mit.edu/courses/mathematics/18-103-fourier-analysis-fall-2013/>
75. Weisstein, Eric W. "Fourier Series--Square Wave." From MathWorld--A Wolfram Web Resource. <http://mathworld.wolfram.com/FourierSeriesSquareWave.html>
76. Smith, S. "The Scientist and Engineer's Guide to Digital Signal Processing". Second Edition. California Tech Publishing. 1999.
77. Feng, J. "Digital Communications and Signal Processing – with Matlab Examples". Department of Computer Science and Centre for Scientific Computing University of Warwick, UK. 2007
78. National Semiconductor Application Note 255. "Power Spectra Estimation". 1980.
79. Wikipedia: Spectral Density: https://en.wikipedia.org/wiki/Spectral_density
80. Stoica, P. Moses, R.. "Spectral Analysis of Signals".(2005)
81. Stein, J. Y. Digital Signal Processing: A Computer Science Perspective. Wiley (2000)
82. Wikipedia: Fourier Transform: https://en.wikipedia.org/wiki/Fourier_transform
83. Wikipedia: Autocorrelation: <https://en.wikipedia.org/wiki/Autocorrelation>
84. Dunn, Patrick F. (2005). Measurement and Data Analysis for Engineering and Science. New York: McGraw–Hill. ISBN 0-07-282538-3.
85. Priestley, M. B. (1982). Spectral analysis and time series. London, New York: Academic Press. ISBN 0125649010.
86. Percival, Donald B.; Andrew T. Walden (1993). Spectral Analysis for Physical Applications: Multitaper and Conventional Univariate Techniques. Cambridge University Press. pp. 190–195. ISBN 0-521-43541-2.
87. Weisstein, Eric W. "Autocorrelation." From MathWorld--A Wolfram Web Resource. <http://mathworld.wolfram.com/Autocorrelation.html>
88. Rei, S., Chicea, D., & Olaru, S. (2016). AUTOCORRELATION FUNCTION ANALYSIS IN PROCESSING STOCHASTIC TIME SERIES. Annals of the University

- Dunarea de Jos of Galati: Fascicle II, Mathematics, Physics, Theoretical Mechanics, 39(1).
89. Weisstein, Eric W. "Wiener-Khinchin Theorem." From MathWorld--A Wolfram Web Resource. <http://mathworld.wolfram.com/Wiener-KhinchinTheorem.html>
 90. Forinash, K. "Sound. An Interactive eBook on the Physics of Sound": <https://soundphysics.ius.edu/>
 91. All About Circuits: Introduction to Analog-to-Digital Converters: <https://www.allaboutcircuits.com/textbook/digital/chpt-13/digital-analog-conversion/>
 92. Kuphaldt, T. "Lessons in Electric Circuits": <https://www.allaboutcircuits.com/textbook/>
 93. Microchip Developer Help: Analog to Digital Converter Operation: <http://microchipdeveloper.com/pwr3101:analog-to-digital-converter-operation>
 94. Dirac, Paul (1958), The Principles of Quantum Mechanics (4th ed.), Oxford at the Clarendon Press, ISBN 978-0-19-852011-5.
 95. Wikipedia: Dirac Delta Function: https://en.wikipedia.org/wiki/Dirac_delta_function
 96. Porat, B. (1994). Digital Processing of Random Signals: Theory & Methods. Prentice Hall. ISBN 0-13-063751-3.
 97. AudioSculpt 3.0 User Manual: <http://support.ircam.fr/docs/AudioSculpt/3.0/co/AudioSculptguideWeb.html>
 98. Wikipedia: Nyquist-Shannon Theorem: https://en.wikipedia.org/wiki/Nyquist%E2%80%93Shannon_sampling_theorem
 99. Burg, Romney, Schwartz. "Digital Sound & Music: Concepts, Applications, and Science". Franklin, Beedle & Associates Inc (October 28, 2016)
 100. An Introduction to Delta Sigma Converters: <http://www.beis.de/Elektronik/DeltaSigma/DeltaSigma.html>
 101. Cooley, James W.; Tukey, John W. (1965). "An algorithm for the machine calculation of complex Fourier series". Math. Comput. 19: 297–301. doi:10.2307/2003354
 102. Englitz, B. "Dynamic Light Scattering". University of California San Diego. 2002.
 103. Sartor, M. "Dynamic Light Scattering". UCSD. 2003.
 104. D. Chicea, "Revealing Fe₃O₄ nanoparticles aggregation dynamics using dynamic light scattering, Optoelectronics and Advanced Materials-Rapid Communications, 3(12), 1299-1305, (2009).
 105. D. Chicea, E. Indrea, C.M. Cretu, "Assesing Fe₃O₄ nanoparticle size by DLS, XRD and AFM", Journal of Optoelectronics and Advanced Materials, 14(5-6), 460-466, (2012).

106. Weisstein, Eric W. "Lorentzian Function." From MathWorld--A Wolfram Web Resource. <http://mathworld.wolfram.com/LorentzianFunction.html>
107. Chicea, D. (2013). Water Suspension Analysis by Modified Dynamic Light Scattering.
108. Chicea, D. (2014). A Simple Algorithm to Simulate Nanoparticles Motion in a Nanofluid. UNIVERSITY POLITEHNICA OF BUCHAREST SCIENTIFIC BULLETIN-SERIES A-APPLIED MATHEMATICS AND PHYSICS, 76(2), 199-206.
109. D.K. Lynch and W. Livingston, "Color and light in nature", Cambridge University Press, 1995 (1st ed.) and 2001 (2nd ed.), ISBN 0 521 77504 3 - see Table 4.3
110. D. Segelstein, "The Complex Refractive Index of Water", M.S. Thesis, University of Missouri, Kansas City (1981). A summary of the refractive index data can be downloaded from here or it is included as "Segelstein.txt" when downloading the MiePlot program.
111. IAPWS 5C: "Release on refractive index of ordinary water substance as a function of wavelength, temperature and pressure" (September 1997) published by International Association for the Properties of Water and Steam (IAPWS)
112. Humboldt State University. GSP216. Electromagnetic Spectrum. http://gsp.humboldt.edu/olm_2015/Courses/GSP_216_Online/lesson1-2/spectrum.html
113. Smith, J. Matlab Function: Air Refractive Index: <https://www.mathworks.com/matlabcentral/fileexchange/31240-air-refractive-index?focused=5186662&tab=function>
114. Phillip E. Ciddor, "Refractive index of air: new equations for the visible and near infrared," Appl. Optics 35, 1566-1573 (1996).
115. B. Edlén, "The refractive index of air," Metrologia 2, 71-80 (1966).
116. K.P. Birch and M.J. Downs, "An updated Edlén equation for the refractive index of air," Metrologia 30, 155-162 (1993).
117. K.P. Birch and M.J. Downs, "Correction to the updated Edlén equation for the refractive index of air," Metrologia 31, 315-316 (1994).
118. Langowski, J. Website: Biophysics of Macromolecules: <https://www.dkfz.de/Macromol/research/dls.html>
119. Danholt Company, ENVIRONMENT: Air filter - lab experiment - LIGHTAIR IonFlow gathers particles. Web: <http://www.danholt.de/english/3820/1727/1727/181001/design1.html>
120. Advanced Water Filters Particles Chart: <http://www.advancedwaterfilters.com/faq-particle-size-chart/>

121. Loschmidt, J. On the Size of the Air Molecules. *Journal of Chemical Education* 1995 72 (10), 870 DOI: 10.1021/ed072p870.2
122. D'Arrigo JS. Screening of membrane surface charges by divalent cations: an atomic representation. *Am J Physiol.* 1978 Sep235(3):C109-17 abstract, p.C109 right column bottom paragraph, p.C110 right column 2nd paragraph & p.C112 left column 2nd paragraph.
123. Engineering Toolbox: Particles Sizes: https://www.engineeringtoolbox.com/particle-sizes-d_934.html
124. Wikipedia: Rayleigh Scattering: https://en.wikipedia.org/wiki/Rayleigh_scattering
125. Barnett, C.E. (1942). "Some application of wavelength turbidimetry in the infrared". *J. Phys. Chem.* 46 (1): 69–75. doi:10.1021/j150415a009
126. Refractive Index Database: <https://refractiveindex.info/?shelf=main&book=Y3A15O12&page=Zelmon>
127. Cecie Starr (2005). *Biology: Concepts and Applications*. Thomson Brooks/Cole. ISBN 0-534-46226-X.
128. Nobbmann, U. Do refractive index and absorption matter for nanoparticles?: <http://www.materials-talks.com/blog/2014/08/05/faq-how-important-are-refractive-index-absorption-for-nanoparticles/>
129. George W. Mulholland, Raymond L. McKenzie, Egon Marx, and Robert A. Fletcher. Refractive index and evaporation rate of individual smoke droplets. *Langmuir* 1985 1 (3), 367-372 DOI: 10.1021/la00063a019.
130. Yamasoe, M. A., Y. J. Kaufman, O. Dubovik, L. A. Remer, B. N. Holben, and P. Artaxo (1998), Retrieval of the real part of the refractive index of smoke particles from Sun/sky measurements during SCAR-B, *J. Geophys. Res.*, 103(D24), 31893–31902, doi:10.1029/98JD01211.
131. Silicon Labs SII133 Data Sheet: <https://www.silabs.com/documents/public/data-sheets/Si1133.pdf>
132. FX Solver: Rayleigh Scattering – Intensity of Light: <https://www.fxsolver.com/browse/formulas/Rayleigh+Scattering+--+Intensity+of+Light>
133. Horiba: Choosing the Concentration Range for DLS Size Measurement: <http://www.horiba.com/scientific/products/particle-characterization/education/sz-100/particle-size-by-dynamic-light-scattering-resources/choosing-concentration-for-dls-size-measurement/>

134. Almeida, R. Rayleigh and Mie Scattering, Colloidal Metals and Photo-elastic Properties. International Materials Institute for New Functionality in Glass, Lehigh University. 2005. <https://www.lehigh.edu/imi/teched/OPG/lecture18.pdf>
135. Prahl, S. Mie Scattering Calculator. Oregon Medical Laser Center. http://omlc.ogi.edu/calc/mie_calc.html
136. Tyler J. Johnson, Jason S. Olfert, Ross Cabot, Conor Treacy, Caner U. Yurteri, Colin Dickens, John McAughey, Jonathan P.R. Symonds, Steady-state measurement of the effective particle density of cigarette smoke, In Journal of Aerosol Science, Volume 75, 2014, Pages 9-16, ISSN 0021-8502, <https://doi.org/10.1016/j.jaerosci.2014.04.006>. (<http://www.sciencedirect.com/science/article/pii/S0021850214000627>)
137. Nobbmann, U. Protein Sizing by Light Scattering, Molecular Weight and Polydispersity. Malvern Instruments. Malvern, Worcestershire. <http://www.nanoparticles.org/pdf/nobbmann.pdf>
138. Jimenez, J.L. Lecture Notes. Aerosol Scattering and Cloud Nucleation. http://cires1.colorado.edu/jimenez/AtmChem/CHEM-5151_S05_L16.pdf
139. Hackley V.A., Clogston J.D. Measuring the Size of Nanoparticles in Aqueous Media Using Batch-Mode Dynamic Light Scattering. NIST Special Publication 1200-6. 2007, rev. 2015. <http://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.1200-6.pdf>
140. Wikipedia: List of Refractive Indexes: https://en.wikipedia.org/wiki/List_of_refractive_indices
141. Research Gate Forum: What is the lowest particle number or concentration for dynamic light scattering to detect? : https://www.researchgate.net/post/What_is_the_lowest_particle_number_or_concentration_for_dynamic_light_scattering_to_detect
142. Lelli L. Lecture: Aerosol and Clouds. Lecture 1. Bremen University, 2014. www.iup.uni-bremen.de/~luca/?%20download=01_LL_VO.pdf
143. Shaw, R. Dynamic Light Scattering. Achieving reliable nano particle sizing. Malvern. <http://149.171.168.221/partcat/wp-content/uploads/Malvern-Zetasizer-LS.pdf>
144. Kondo K., Masaki S., Tabuchi T. Measurement of Particles in Liquid Materials Using the Light Scattering Method. 2013. http://www.rion.co.jp/english/product/docs/p_tech03.pdf

145. Malvern Technical Note: Dynamic Light Scattering, and Introduction in 30 Minutes. https://warwick.ac.uk/fac/cross_fac/sciencecity/programmes/internal/themes/am2/booking/particlesize/intro_to_dls.pdf
146. Physics. StackExchange Forum: Dependence of scattering on particles size and refractive index: <https://physics.stackexchange.com/questions/143438/dependence-of-scattering-on-particle-size-and-refractive-index>
147. Born M., Wolf E. Principles of Optics. Cambridge University Press; 7th edition (October 13, 1999)
148. Richardson, H. H., Carlson, M. T., Tandler, P. J., Hernandez, P., & Govorov, A. O. (2009). Experimental and theoretical studies of light-to-heat conversion and collective heating effects in metal nanoparticle solutions. Nano Letters, 9(3), 1139–1146. <http://doi.org/10.1021/nl8036905>.
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2669497/>
149. Geints, Y. E., & Zemlyanov, A. A. (2017). Optimal conditions for laser-induced heating of a double-shell spherical nanocapsule. Journal of Applied Physics, 121(12), 123111.
150. Astafyeva, L. G., Voshchinnikov, N. V., & Waters, L. B. (2002). Heating of three-layer solid aerosol particles by laser radiation. Applied optics, 41(18), 3700-3705.
151. Pustovalov, V.K. Theoretical study of heating of spherical nanoparticle in media by short laser pulses. Department of Innovation Research, Belarussian Institute of System Analysis, Masherov Pr., 7, Minsk 220004, Belarus. Chem. Phys. 308 (2005) 103-108. Elsevier.
152. Texas Instruments: Selecting an A/D Converter. <http://www.ti.com/lit/an/sbaa004a/sbaa004a.pdf>
153. LaserPoints: Laser Buying Guide: <http://www.laserpoints.com/laser-buying-guide>
154. Value Amrita: Laser beam divergence and spot size: <http://vlab.amrita.edu/?sub=1&brch=189&sim=342&cnt=1>
155. Jacobs, G. Understanding Spot Size for Laser Scanning. Professional Surveyor Magazine. 2006. https://hds.leica-geosystems.com/hds/en/Prof_Surv_Spot_Size_Oct06.pdf
156. Koechner, Walter. Solid-State Laser Engineering. Berlin: Springer, 2006.
157. Ion, John. Laser Processing of Engineering Materials. Amsterdam: Elsevier/Butterworth-Heinemann, 2005.
158. Laser Surveying. London: Van Nostrand Reinhold (International), 1989.

159. Technical Data Sheet 1206 Package Phototransistor
<https://www.robofun.ro/docs/ELPT15-21C.pdf>
160. Karki, J. Understanding Operational Amplifier Specifications. Texas Instruments. 1998.
<http://www.ti.com/lit/an/sloa011/sloa011.pdf>
161. Texas Instruments NE5532x, SA5532x Dual Low-Noise Operational Amplifiers Data Sheet. <http://www.ti.com/lit/ds/symlink/ne5532.pdf>
162. Burr-Brown OPT 301 INTEGRATED PHOTODIODE AND AMPLIFIER Data Sheet.
<http://www.ti.com/lit/ds/sbbs001/sbbs001.pdf>
163. Electronics Tutorials: Frequency Response: <http://www.electronicstutorials.ws/amplifier/frequency-response.html>
164. Teensy 3.0, 3.1, 3.2, LC, 3.5, and 3.6 ADC implementation library created by Pedro Villanueva. <https://github.com/pedvide/ADC>
165. Rei, S. Data Acquisition System Based on ATmega328 Microcontroller. “Lucian Blaga” University of Sibiu, Master of Engineering Thesis, Sibiu, 2015.
166. Malvern Frequently Asked Questions: Calculating Volume Distributions from DLS Data: <http://www.materials-talks.com/wp-content/uploads/2015/08/FAQ-Mie-Equations.pdf>
167. Christopher M. Bishop. 1995. Neural Networks for Pattern Recognition. Oxford University Press, Inc., New York, NY, USA.
[http://cs.du.edu/~mitchell/mario_books/Neural Networks for Pattern Recognition -
 _Christopher_Bishop.pdf](http://cs.du.edu/~mitchell/mario_books/Neural_Networks_for_Pattern_Recognition_-_Christopher_Bishop.pdf)
168. Simon Haykin. 1998. Neural Networks: A Comprehensive Foundation (2nd ed.). Prentice Hall PTR, Upper Saddle River, NJ, USA.
[https://cdn.preterhuman.net/texts/science_and_technology/artificial_intelligence/Neural%
 20Networks%20-%20A%20Comprehensive%20Foundation%20-
 %20Simon%20Haykin.pdf](https://cdn.preterhuman.net/texts/science_and_technology/artificial_intelligence/Neural%20Networks%20-%20A%20Comprehensive%20Foundation%20-%20Simon%20Haykin.pdf)
169. Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth. Matlab Neural Network Toolbox™ User's Guide. 2017 https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf
170. Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesus. Neural Network Design (2nd Edition). 2014. <http://hagan.okstate.edu/nnd.html>
171. Mathworks: Introducing Deep Learning with Matlab. 2017.
172. G. Cybenko. Approximation by Superpositions of a Sigmoidal Function. Mathematics of Control Signals, and Systems (1989) 2: 303-314. Springer – Verlag.

173. K. Hornik. Approximation Capabilities of Multilayer Feedforward Networks. Neural Networks, Vol. 4, pp. 251-257, 1991.
174. Csasji, B.C. Approximation with Neural Networks. MSc Thesis. Faculty of Sciences. Eotvoes Lorand University, Hungary. 2001.
175. M. Turhan. Neural Networks and Computation of Neural Network Weights and Biases by the Generalized Delta Rule and Backpropagation of Errors. Rock Solid Images 1995.
176. Anil K. Jain, Jianchang Mao. Artificial Neural Networks: A Tutorial. 1996.
177. Ben Kroese, Patrick von der Smagt. An Introduction to Neural Networks. University of Amsterdam. 1996.
178. Kevin Gurney. An Introduction to Neural Networks. University of Sheffield. 1997. UCL Press.
179. Dayan, Peter. L.F., Abbott. Theoretical Neuroscience. Massachusetts Institute of Technology. 2001.
180. David, Kriesel. A Brief Introduction to Neural Networks. 2007.
181. J. Roell. From Fiction to Reality: A Beginner's Guide to Artificial Neural Networks. <https://towardsdatascience.com/from-fiction-to-reality-a-beginners-guide-to-artificial-neural-networks-d0411777571b>
182. Alex Smola and S.V.N. Vishwanathan. Introduction to Machine Learning. Cambridge University Press 2008.
183. P. Harrington. Machine Learning in Action. Manning Publications. 2012.
184. Li Deng, Dong Yu. Deep Learning Methods and Applications. Foundations and Trends in Signal Processing. Vol.7, No. 3-4 (2013), 197-387.
185. F. Agostinelli, M Hoffman, P. Sadowski, P. Baldi. Learning Activation Functions to Improve Deep Neural Networks. ICLR 2015.
186. Mathworks Forum: Write CSW from Matlab: <https://www.mathworks.com/help/matlab/ref/csvwrite.html>
187. NIST/SEMATECH e-Handbook of Statistical Methods, <http://www.itl.nist.gov/div898/handbook/>
188. Stackoverflow Forum: Transposing a Matrix from a 2D Array: <http://stackoverflow.com/questions/26197466/transposing-a-matrix-from-a-2d-array>
189. Mathworks Forum: How to separate biases and weights - Matlab NN: <https://www.mathworks.com/help/nnet/ref/separatwb.html>
190. Processing Forum: Matrix multiplication: https://processing.org/discourse/beta/num_1206855932.html

191. Ario Muhammad, Java probabilistic functions:
<https://arioresearch.wordpress.com/2012/11/08/java-1-calculate-some-probabilistic-equations/>
192. Processing Forum: How to read/write numeric data in Processing/Java(See also code at the end of this): https://processing.org/discourse/beta/num_1263473746.html
193. Mathworks Forum: Matlab neural networks - getx function:
https://www.mathworks.com/matlabcentral/newsreader/view_thread/13060
194. Mathworks Forum: Matlab neural networks - getwb function:
<https://www.mathworks.com/help/nnet/ref/getwb.html>
195. Mathworks Forum: Matlab neural networks - how to show the weight and bias:
<https://www.mathworks.com/matlabcentral/answers/2356-how-to-show-the-weight-or-bias-in-a-neural-network>
196. Pyren Neural Network: How to load a Matlab NN in Python:
<http://pyrenn.readthedocs.io/en/latest/save.html>
197. Neural Network Blog: Neural Networks in VBA/Excel:<https://quantmacro.wordpress.com/2015/08/13/artificial-neural-network-with-backpropagation-training-in-vba/>
198. How to Implement XOR Function in Excel: <http://powerspreadsheets.com/xor-function-excel/>
199. Barber, S. Codeproject: Neural Networks for beginners:
<https://www.codeproject.com/Articles/16419/AI-Neural-Network-for-beginners-Part-of>
200. Excel Perceptron Example:
https://www.google.ro/url?sa=t&rct=j&q=&esrc=s&source=web&cd=4&cad=rja&uact=8&ved=0ahUKEwj_7oeXkLzRAhUZYFAKHTtBBmEQFgg4MAM&url=http%3A%2F%2Fwww.cs.nott.ac.uk%2F~pszgzk%2Fcourses%2Fg5ai%2F006neuralnetworks%2Fperceptron.xls&usq=AFQjCNG4NbnfwCaw4PTuGamEgYHDmVLrTg&sig2=mOO5OwjHpXmIlg24IgHgXA
201. Neural Network Blog: Simple VB example of NN:
<http://excelneuralnetwork.blogspot.ro/2014/09/simple-example-of-neural-networks.html>
202. Website: Computational Neuroscience in Excel: <http://toritris.weebly.com/>
203. Neural Network XOR Backpropagation Example in Excel:
<https://www.google.ro/url?sa=t&rct=j&q=&esrc=s&source=web&cd=16&cad=rja&uact=8&ved=0ahUKEwi-6suDI7zRAhXChRoKHXyAaA5Q4ChAWCDwwBQ&url=http%3A%2F%2Fmorphiles.co>

m%2Fwp-

content%2Fuploads%2F2013%2F05%2FXOR_BackPropagation_Example.xls&usg=AFQjCNHHKJ7suhX-82hnl-obVsUTrPimvg&sig2=3SQ56xsmmeItzW_CHex0Pg

204. Michael A. Nielsen, "Neural Networks and Deep Learning", Determination Press, 2015:
<http://neuralnetworksanddeeplearning.com/index.html>
205. Mathworks Forum: Hyperbolic tangent sigmoid transfer function (Matlab implementation):
<https://www.mathworks.com/help/nnet/ref/tansig.html?requestedDomain=www.mathworks.com>
206. Karpathy, A. Hacker`s Guide to Neural Networks: <http://karpathy.github.io/neuralnets/>
207. Linkedin Forum: Neural Networks Implementation in Matlab:
<https://www.linkedin.com/pulse/neural-networks-implementation-matlab-randa-elanwar>
208. Stackoverflow Forum: Export a Neural Network trained with Matlab in other programming languages: <http://stackoverflow.com/questions/15526112/export-a-neural-network-trained-with-matlab-in-other-programming-languages>
209. Spencer-Harper, M. How to Build a Simple NN in Python in 9 Lines of Code. 2015.
<https://medium.com/technology-invention-and-more/how-to-build-a-simple-neural-network-in-9-lines-of-python-code-cc8f23647ca1#.rotvopz7g>
210. Spencer-Harper, M. How to Build a Multi Layered Neural Network in Python. 2015
<https://medium.com/technology-invention-and-more/how-to-build-a-multi-layered-neural-network-in-python-53ec3d1d326a>
211. Anguelov, B. Basic Neural Network Theory. 2008.
<https://takinginitiative.wordpress.com/2008/04/03/basic-neural-network-tutorial-theory/>
212. Anguelov, B. Basic Neural Network Implementation in C++. 2008.
<https://takinginitiative.wordpress.com/2008/04/23/basic-neural-network-tutorial-c-implementation-and-source-code/>
213. Tulleken, H. 15 Steps to Implement a Neural Network. 2009. <http://code-spot.co.za/2009/10/08/15-steps-to-implemented-a-neural-net/>
214. Shiffman, D. The Nature of Code: Simulating Natural Systems with Processing.
<http://natureofcode.com/book/chapter-10-neural-networks/>
215. Miller, S. How to Build a Neural Network. 2015. <http://stevenmiller888.github.io/mind-how-to-build-a-neural-network/>
216. Britz, D. Implementing a NN from Scratch. 2015.
<http://www.wildml.com/2015/09/implementing-a-neural-network-from-scratch/>

217. Scott C. Neural Network in Processing (2017).
<http://arduinoasics.blogspot.ro/2011/08/neural-network-part-1-connection.html>
218. Stanford University Lectures. CS231n Convolutional Neural Networks for Visual Recognition. <http://cs231n.github.io/>
219. Willems, K. Deep Learning in Python. 2017. Datacamp.
<https://www.datacamp.com/community/tutorials/deep-learning-python>
220. Freund, Y.; Schapire, R. E. (1999). "Large margin classification using the perceptron algorithm" (PDF). Machine Learning. 37 (3): 277–296. doi:10.1023/A:1007662407062.
221. H. Lohninger. Fundamentals of Statistics. Online Lecture Notes.
http://www.statistics4u.com/fundstat_eng/cc_classif_calib.html
222. M. Minsky and S. Papert, Perceptrons, Cambridge, MA. MIT Press, 1969.
223. Fjodor van Veen. A Mostly Complete Chart of Neural Networks.
<http://www.asimovinstitute.org/neural-network-zoo/>
224. Aytul Sofu, Fatma Yesim Ekinci. Estimation of Storage Time of Yogurt with Artificial Neural Network Modeling. August 2007. Journal of Dairy Science 90(7):3118-25. DOI 10.3168/jds.2006-591.
225. Mathworks: Supervised Learning: https://www.mathworks.com/discovery/supervised-learning.html?s_tid=srchtitle
226. Mathworks: Unsupervised Learning:
<https://www.mathworks.com/discovery/unsupervised-learning.html>
227. Dustin Stansbury. Topic in Computational Neuroscience and Machine Learning. Derivation: Error Backpropagation & Gradient Descent for Neural Networks. 2014.
<https://theclevermachine.wordpress.com/2014/09/06/derivation-error-backpropagation-gradient-descent-for-neural-networks/>
228. Alex Minnaar. Deep Learning Basics: Neural Networks, Backpropagation and Stochastic Gradient Descent. 2015. <http://alexminnaar.com/deep-learning-basics-neural-networks-backpropagation-and-stochastic-gradient-descent.html>
229. Wikipedia: Backpropagation. <https://en.wikipedia.org/wiki/Backpropagation>
230. ConvnetJS demo: toy 2d classification with 2-layer neural network.
<http://cs.stanford.edu/people/karpathy/convnetjs/demo/classify2d.html>
231. TensorFlow Playground. <http://playground.tensorflow.org/>
232. Jeff Heaton. Introduction to Neural Networks for Java, 2nd Edition. Heaton Research, Inc.; 2 edition (October 1, 2008)

233. Stackexchange Forum: How to choose the number of hidden layers and nodes in a feedforward neural network? <https://stats.stackexchange.com/questions/181/how-to-choose-the-number-of-hidden-layers-and-nodes-in-a-feedforward-neural-netw>
234. Timothy Masters. Practical Neural Network Recipes in C++. Morgan Kaufmann; 1 edition (April 14, 1993)
235. Cireşan, Dan C., Ueli Meier, and Jürgen Schmidhuber. "Transfer learning for Latin and Chinese characters with deep neural networks." In The 2012 International Joint Conference on Neural Networks (IJCNN), pp. 1-6. IEEE, 2012.
https://scholar.google.com/scholar?cluster=7452424507909578812&hl=en&as_sdt=0,22 ;
http://people.idsia.ch/~cirestan/data/ijcnn2012_v9.pdf.
236. Slav Ivanov. 37 Reasons why your Neural Network is not working. 2017.
<https://blog.slavv.com/37-reasons-why-your-neural-network-is-not-working-4020854bd607>
237. Neuralware Frequently Asked Questions.
<http://www.neuralware.com/index.php/frequently-asked-questions>
238. Dan CHICEA, Silviu REI. SIMPLE ALGORITHMS TO GENERATE DYNAMIC LIGHT SCATTERING TIME SERIA. 16th International Balkan Workshop on Applied Physics. Constanta, Romania, 2016. http://ibwap.univ-ovidius.ro/2016/uploads/template/Proceeding_IBWAP%202016.pdf
239. D. Chicea, CHODIN- a Computer Code to Simulate Coherent Light Scattering Dynamics on Biological Suspensions, Proceedings of SPIE Volume: 7007, DOI: 10.1117/12.801959, (2007).
240. D. Chicea, Computer Simulation Results of Light Scattered on Red Blood Cells, Romanian Journal of Physics, 51(3-4), 403-409, (2006).
241. REI Silviu, CHICEA Dan, ILIE Beriliu, OLARU Sorin. DYNAMIC LIGHT SCATTERING SIGNAL CONDITIONING FOR DATA PROCESSING. 3rd International Conference for Doctoral Students - IPC 2017 June 22-23, 2017 Braşov, Romania.
242. Liber Tecnologia. Raspberry Pi Zero W, il mini computer con Wi-Fi da 10 euro.
<https://tecnologia.libero.it/raspberry-pi-zero-w-mini-computer-10-euro-8833>
243. Raspberry Pi Foundation. <https://www.raspberrypi.org/>
244. Mathworks: Improve Neural Network Generalization and Avoid Overfitting.
<https://www.mathworks.com/help/nnet/ug/improve-neural-network-generalization-and-avoid-overfitting.html>

245. Mathworks: How to Save and Reuse a Trained Neural Network.
<https://www.mathworks.com/matlabcentral/answers/264160-how-to-save-and-reuse-a-trained-neural-network>
246. Mathworks: Analyze Shallow Neural Network Performance After Training:
<https://www.mathworks.com/help/nnet/ug/analyze-neural-network-performance-after-training.html>
247. Dan Chicea, Silviu Rei, Liana Chicea. A Fast Algorithm for Profiling Suspensions in Natural Water Using Dynamic Light Scattering and Artificial Neural Networks Procedure. AQUATIC BIODIVERSITY INTERNATIONAL CONFERENCE.25 - 28 September, 2019, Sibiu, Transylvania, Romania.
248. Silviu Rei. Implementing A Low Cost Data Acquisition System for Engineering Education Programs in Universities. Proceedings of the BRCEBE-ICEBE'17 Conference, Sibiu, Romania.
249. Silviu Rei, Dan Chicea. USING DYNAMIC LIGHT SCATTERING EXPERIMENTAL SETUP AND NEURAL NETWORKS FOR PARTICLE SIZING. 3rd International Conference for Doctoral Students - IPC 2017 June 22-23, 2017 Braşov, Romania.
250. Mathworks: Choose a Multilayer Neural Network Training Function:
<https://www.mathworks.com/help/nnet/ug/choose-a-multilayer-neural-network-training-function.html>
251. Particle Size Distribution Functions.
<http://www.eng.uc.edu/~beaucag/Classes/Nanopowders/ParticleSizeDistribuhtml/ParticleSizeDistribu.htm>
252. John, V., Angelov, I., Öncül, A.A., Thévenin, D. Techniques for the reconstruction of a distribution from a finite number of its moments. Chemical Engineering Science, Volume 62, Issue 11, June 2007. Elsevier.
253. Robert M. Mnatsakanov¹, and Artak S. Hakobyan². Recovery of Distributions via Moments (2009), IMS Lecture Notes–Monograph Series Optimality: The Third Erich L. Lehmann Symposium Vol. 57 (2009) 252–265c Institute of Mathematical Statistics, 2009.
https://projecteuclid.org/download/pdfview_1/euclid.lnms/1249305333
254. G. Golub, B. Gustafsson, P. Milanfar, P. Putinar, J. Varah: Shape reconstruction from moments: theory, algorithms, and applications, SPIE Proceedings vol. 4116 (2000), Advanced Signal Processing, Algorithms, Architecture, and Implementations X (Franklin T.~Luk, ed.) pp. 406--416. <https://people.kth.se/~gbjorn/golub.pdf>

255. L.G.M. de Souza a, G. Janiga a, V. John b,c, D. The´venin a, Reconstruction of a distribution from a finite number of moments with an adaptive spline-based algorithm, *Chemical Engineering Science* 65 (2010) 2741–2750 https://www.wias-berlin.de/people/john/ELECTRONIC_PAPERS/SJTT10.CES.pdf
256. Parthapratim Biswas. Department of Physics and Astronomy, The University of Southern Mississippi, Hattiesburg, MS 39406, USA* Arun K. Bhattacharya Department of Physics, The University of Burdwan, Burdwan, WB 713104, India Function reconstruction as a classical moment problem: A maximum entropy approach. arXiv:1004.4928v1 [math-ph] 27 Apr 2010 <https://arxiv.org/pdf/1004.4928.pdf>
257. G. Cogoni and P. J. Frawley, Particle Size Distribution Reconstruction Using a Finite Number of Its Moments through Artificial Neural Networks: A Practical Application. *Crystal Growth & Design* 2015 15 (1), 239-246.DOI: 10.1021/cg501288z. <http://pubs.acs.org/doi/abs/10.1021/cg501288z>
258. V. M. Adamyán, J. Alcober, and I. M. Tkachenko, Reconstruction of Distributions by Their Moments and Local Constraints, *AMRX Applied Mathematics Research eXpress* 2003, No. 2. https://oup.silverchair-cdn.com/oup/backfile/Content_public/Journal/amrx/2003/2/10.1155_S1687120003212028/3/2003-2-33.pdf?Expires=1498815120&Signature=agUYSgscJj-XM5tgyfcFY8HVBZmGloAVacO9ywsJPVtYi6C9jH8UeT1wocJ~dqHQCGNEIUbt3losSuDjP1HvpxQc2HyGTmRez7RSSL3c-wET8hYYxJH4Q3Gm41VoWKjh-CD3Lc4bal0SSJDvwWoKKkkZ18tEXUKince3QXHenYhmszBtHgw4GkMpWStRgpDKrtgpA8yt4qe4o1vhhJRvilipt-WkfN-QdQp~zXu-UTnL44dQL-310VEx7IM2yFrMOfrvo4~cF9VQzNIPwoAkJe8p9eh9ndWn2NRCZyN~f6fTfHEESuqBwI-GEhovkqA2n7tBDKmyjt~J5-3DnExyxQ_&Key-Pair-Id=APKAIUCZBIA4LVPVW3Q
259. Tony Saad, University of Utah, Salt Lake City, UT 84112, USA, The Maximum Entropy Method for Reconstructing Density Distributions. <http://www.tonysaad.net/docs/tsaad-maximum-entropy-method.pdf>
260. John, V., Univ. des Saarlandes Angelov, I., Max Planck Institute for Dynamics of Complex Technical Systems Öncül, A. A., Otto-von-Guericke-Univ. Magdeburg (287p) Towards the Optimal Reconstruction of a Distribution from Its Moments, Conference: AIChE Annual Meeting Year: 2005 <https://www.aiche.org/conferences/aiche-annual-meeting/2005/proceeding/paper/287p-towards-optimal-reconstruction-distribution-its-moments-0>

261. G Talenti Recovering a function from a finite number of moments
<http://iopscience.iop.org/article/10.1088/0266-5611/3/3/016/meta>
262. Weisstein, Eric W. "Raw Moment." From MathWorld--A Wolfram Web Resource.
<http://mathworld.wolfram.com/RawMoment.html>
263. Malvern. Frequently Asked Questions. <http://www.materials-talks.com/wp-content/uploads/2015/08/FAQ-Mie-Equations.pdf>
264. Piederrière Y, Cariou J, Guern Y, Le Jeune B, Le Brun G, Lotrian J 2004 Scattering through fluids: speckle size measurement and Monte Carlo simulations close to and into the multiple scattering, *Optics Express* 12, 176-188,
265. Piederriere Y, Le Meur J, Cariou J, Abgrall JF, Blouch MT, 2004 Particle aggregation monitoring by speckle size measurement; application to blood platelets aggregation, *Optics Express* 12, 4596-4601.
266. Chicea D 2007 Speckle size, intensity and contrast measurement application in micron-size particle concentration assessment, *European Physical Journal Applied Physics* 40, 305-310, DOI: 10.1051/epjap:2007163
267. Goodman JW 1984 Laser speckle and related phenomena, Vol.9 in series Topics in Applied Physics, J.C. Dainty, Ed., Springer-Verlag, Berlin, Heidelberg, New York, Tokyo.
268. Xu R Particle Characterization: Light Scattering Methods 2002 Kluwer Academic Publishers, New York, Boston, Dordrecht, London, Moscow.
269. Chicea D 2012 A Study of Nanoparticle Aggregation by Coherent Light Scattering, *Current Nanoscience* 8(2), 259-265.
270. Haykin, S 1999 Artificial neural networks: A Comprehensive Foundation, Prentice Hall, ISBN 0-13-273350-1.
271. Carrieri AH 1999 Artificial neural network pattern recognition by means of differential absorption Mueller matrix spectroscopy, *Applied Optics* 38(17) 3759-3766.
272. Berdnik VV, Loiko VA 2009 Retrieval of size and refractive index of spherical particles by multiangle light scattering: artificial neural network method application, *Applied Optics* 48(32) 6178-6187.
273. Berdnik VV Mukhamedjarov RD, Loiko VA, 2004 Characterization of optically soft spheroidal particles by multiangle light-scattering data by use of the neural-networks method, *Optics Letters* 29(9) 1019-1021.
274. Kaye P, Hirst E, Wang-Thomas Z, 1997 Neural-network-based spatial light-scattering instrument for hazardous airborne fiber detection, *Applied Optics* 36(24) 6149-6156.

275. Ulanowski Z, Wang Z, Kaye P, Ludlow IK 1998 Application of artificial neural networks to the inverse light scattering problem for spheres, *Applied Optics* 37(18) 4027-4033.
276. Chicea D 2017 Using artificial neural networks for dynamic light scattering time series processing, *Measurement Science and Technology* 28(5) 055206.
277. Einstein, A. (1905). "Über die von der molekularkinetischen Theorie der Wärme geforderte Bewegung von in ruhenden Flüssigkeiten suspendierten Teilchen". *Annalen der Physik* (in German). 322 (8): 549–560. Bibcode:1905AnP...322..549E. doi:10.1002/andp.19053220806
278. Stetefeld J, McKenna SA, Patel TR. 2016 Dynamic light scattering: a practical guide and applications in biomedical sciences, *Biophysical Reviews*;8(4):409-427, doi:10.1007/s12551-016-0218-6.
279. Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth. *Matlab Artificial neural network Toolbox™ User's Guide*. 2017 https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf
280. Duhamel P., Vetterli M., *Fast Fourier Transforms: A Tutorial Review and a State of the Art*, *Signal Processing*, Vol. 19, 259-299, (1990).
281. Dubin S.B. , Lunacek J.H., Benedek G.B., *Observation of the Spectrum of Light Scattered by Solutions of Biological Macromolecules*, *PNAS*, 57(5), 1164-1171 (1967)
282. Shannon C.E., *A Mathematical Theory of Communication*, *Bell System Technical Journal*, 27(4): 623–666, (1948), doi:10.1002/j.1538-7305.1948.tb00917.x.
283. Whittaker E.T. , *On the Functions Which are Represented by the Expansions of the Interpolation Theory*, *Proc. Royal Soc. Edinburgh*. 35: 181–194, doi:10.1017/s0370164600017806, (1915).
284. Nyquist H., *Certain topics in telegraph transmission theory*, *Trans. AIEE*, 47, 363- 390, (1928).
285. Kotelnikov V.A. , *On the transmission capacity of the ‘ether’ and of cables in electrical communications*, *Proceedings of the first All-Union Conference on the technological reconstruction of the communications sector and the development of low-current engineering*, Moscow, (1933).
286. Levenberg K, *A Method for the Solution of Certain Problems in Least Squares*, *Quart. Appl. Math.*, 2, 164-168, (1944).
287. Karl Pearson (1895) "Notes on regression and inheritance in the case of two parents," *Proceedings of the Royal Society of London*, 58 : 240–242.

288. Stigler, S. M. (1989). "Francis Galton's Account of the Invention of Correlation". *Statistical Science*. 4 (2): 73–79. doi:10.1214/ss/1177012580.
289. de Kruif C. G. (Kees), Huppertz T., 2012, Casein Micelles: Size Distribution in Milks from Individual Cows, *J. Agric. Food Chem.*, 60 (18), pp 4649–4655, DOI: 10.1021/jf301397w.
290. Mootse H., Pisponen A., Pajumägi S., Polikarpus A., Tatar V, Sats A. and Poikalainen V., 2014, Investigation of Casein Micelle Particle Size Distribution in Raw Milk of Estonian Holstein Dairy Cows, *Agronomy Research* 12(3), 753–758.
291. BioNumbers Database: Milo et al. *Nucl. Acids Res.* (2010) 38 (suppl 1): D750-D753.
292. Python Website: <https://www.python.org/>
293. Tensorflow Website: <https://www.tensorflow.org/>
294. Theano Website: <http://deeplearning.net/software/theano/>
295. Keras Website: <https://keras.io/>
296. Keras Activation Functions: <https://keras.io/activations/#available-activations>
297. Keras Optimizers: <https://keras.io/optimizers/>
298. Diederik Kingma, Jimmy Ba, Adam: A Method for Stochastic Optimization. Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego, 2015. arXiv:1412.6980
299. Sashank J. Reddi, Satyen Kale, Sanjiv Kumar, On the Convergence of Adam and Beyond. 15 Feb 2018 (modified: 27 Mar 2018)ICLR 2018 Conference Blind Submission.
300. Dan Chicea, Silviu Rei, A fast artificial neural network approach for dynamic light scattering time series processing, *Measurement Science and Technology*, 29(2018) 105201 (15pp), IOP Publishing, <https://doi.org/10.1088/1361-6501/aad937>