

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INFORMATYKA TECHNICZNA I TELEKOMUNIKACJA

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Tomasz Mrozek

**Wykorzystanie metody asynchronicznego próbkowania sygnałów
i splotowych sieci neuronowych do oceny jakości transmisji optycznej**

Promotor

dr hab. inż. Krzysztof Perlicki, profesor uczelni

Promotor pomocniczy

dr Piotr Wasilewski

WARSZAWA 2022

Pragnę gorąco podziękować

*Rodzicom
za wiarę w moje możliwości oraz motywację na każdym etapie życia,*

*Żonie Kasi
za okazaną wyrozumiałość i cierpliwość, przy pracy do późna w nocy,*

*Siostrze Klaudii
za ciepłe słowa i trzymanie kciuków,*

*Promotorowi
za ogromną pomoc, życzliwość, wnikliwe uwagi i wsparcie w realizacji rozprawy,*

*Promotorowi pomocniczemu
za wsparcie we wprowadzeniu w tematykę splotowych sieci neuronowych,*

*Kolegom z Instytutu Telekomunikacji
za pomoc i dobre rady.*

Streszczenie

Rozprawa doktorska została poświęcona badaniom nad możliwością zastosowania metody asynchronicznego próbkowania z opóźnieniem ADTS (ang. *Asynchronous Delay Tap Sampling*) do monitorowania zjawisk zachodzących w warstwie fizycznej sieci optycznej oraz splotowych sieci neuronowych CNN (ang. *Convolutional Neural Network*) do wyznaczania wartości liczbowych parametrów opisujących monitorowane zjawiska. W wyniku przeprowadzonych badań uzyskano bardzo dobre wyniki monitorowania oraz wyznaczania wartości trzech równocześnie występujących zjawisk, czyli dyspersji chromatycznej, przeniku optycznego oraz szumu wzmocnionej emisji spontanicznej ASE (ang. *Amplified Spontaneous Emission*) dla modulacji fazy DPSK (ang. *Differential Phase Shift Keying*) i natężenia światła OOK (ang. *On-Off Keying*). Połączenie techniki ADTS oraz CNN pozwala na stworzenie metody i układu pomiarowego do jej realizacji, który charakteryzuje się właściwościami spełniającymi wymagania stawiane nowoczesnym metodom monitorowania wydajności pracy współczesnych systemów transmisji optycznej.

Słowa kluczowe:

Telekomunikacja światłowodowa, Monitorowanie jakości transmisji optycznej, Asynchroniczne próbkowanie z opóźnieniem, Splotowe sieci neuronowe

Abstract

The PhD thesis was devoted to research on the possibility of using the Asynchronous Delay Tap Sampling (ADTS) method to monitor the phenomena occurring in the physical layer of the optical network and the Convolutional Neural Network (CNN) algorithms to determine the numerical values of parameters describing monitored phenomena. As a result of the conducted research, very good results of monitoring and determining the values of three simultaneously occurring phenomena of Chromatic Dispersion, Optical Crosstalk and Amplified Spontaneous Emission (ASE) noise for Differential Phase Shift Keying (DPSK) and On-Off Keying (OOK) modulation were obtained. The combination of the ADTS technique and CNN algorithms allows for the creation of a method and measurement system for its implementation, which is characterized by properties that meet the requirements for modern methods of monitoring the performance of modern optical transmission systems.

Keywords:

Optical fiber communications, Optical Performance Monitoring, Asynchronous Delay Tap Sampling, Convolutional Neural Networks

Spis treści

Streszczenie.....	5
Abstract	6
Spis treści	7
Wykaz skrótów.....	9
1. Wprowadzenie i cel pracy.....	15
2. Zakłócenia w warstwie fizycznej.....	18
3. Metody pomiaru jakości transmisji optycznej	22
3.1 Metody pomiaru jakości sygnału optycznego	23
3.1.1 Pomiar aktywny	24
3.1.2 Pomiar bierny.....	25
3.2 Metody pomiaru jakości sygnału elektrycznego	26
3.2.1 Wykres oczkowy.....	27
3.2.2 Metoda oparta o monitorowanie podnośnej sygnału	29
3.2.3 Technika asynchronicznego histogramu amplitudy	30
3.2.4 Parametryczny asynchroniczny wykres oka	32
3.2.5 Technika monitorowania parametrów z zrekonstruowanego wykresu oczkowego	34
3.2.6 Asynchroniczne próbkowanie z opóźnieniem	35
4. Splotowe sieci neuronowe	45
4.1 Splot.....	46
4.2 Sieci neuronowe ze splotem	47
4.2.1 Sieć LeNet-5	51
4.3 Wykorzystanie splotowych sieci neuronowych do wyznaczania wartości liczbowych monitorowanych parametrów	55
5. Uczenie splotowej sieci neuronowej.....	59
5.1 Przygotowanie danych do procesu uczenia splotowej sieci neuronowej	61
5.2 Budowa splotowej sieci neuronowej oraz ustawienia przyjęte dla procesu uczenia	62
5.3 Uczenie sieci splotowej z wykorzystaniem danych pochodzących z metody asynchronicznego próbkowania z opóźnieniem	66
5.4 Podsumowanie wyników uczenia sieci splotowej	85
6. Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska ..	89

7. Podsumowanie	110
Literatura	112
Wykaz rysunków	121
Wykaz tabel	123

Wykaz skrótów

W rozprawie doktorskiej wykorzystano następujące skróty:

AAH	Asynchronous Amplitude Histogram Asynchroniczny histogram amplitudy
ADAM	Adaptive Moment Estimation Adaptacyjny algorytm optymalizacji szybkości uczenia
ADTS	Asynchronous Delay Tap-Sampling Asynchroniczne próbkowanie z opóźnieniem
ASE	Amplified Spontaneous Emission Szum wzmacnionej emisji spontanicznej
BER	Bit Error Rate Bitowa stopa błędów
CD	Chromatic Dispersion Dyspersja chromatyczna
CNN, ConvNet	Convolutional Neural Network Splotowe sieci neuronowe
CSRZ-DPSK	Carrier-Suppressed Return to Zero Differential Phase Shift Keying Kod z powrotem do zera z wytłumioną nośną z różnicową modulacją z kluczowaniem fazy
CZT	Chirp Z-transform Transformata świergotowa, Z-transformata
CZTSS	Chirp Z-transform Software Synchronization Transformata świergotowa z synchronizacją programową
DCF	Dispersion Compensating Fiber Światłowód ze skompensowaną dyspersją

DFT	Discrete Fourier Transform Dyskretna transformata Fouriera
DGD	Differential Group Delay Różnicowe opóźnienie grupowe
DPSK	Differential Phase Shift Keying Różnicowa modulacja z kluczowaniem fazy
DSP	Digital Signal Processing Cyfrowe przetwarzanie sygnałów
DWDM	Dense Wavelength Division Multiplexing Gęste zwielokrotnienie falowe
DQPSK	Differential Quarternary Phase Shift Keying Różnicowa kwadraturowa modulacja z kluczowaniem fazy
EAM	Electro-Absorption Modulator Modulator elektro-absorpcyjny
EDFA	Erbium Doped fiber amplifier Wzmacniacz światłowodowy domieszkowany erbem
FEC	Forward Error Correction Korekcja błędów z wyprzedzeniem
FWM	Four Wave Mixing Mieszanie czterofalowe
HD	High Definition Wysoka rozdzielczość (1920x1080)
ITU-T	International Telecommunication Union – Telecommunication Standardization Sector Międzynarodowy Związek Telekomunikacyjny – Sektor standaryzacji

LSTM	Long Short Term Memory Sieci długookresowej pamięci
MT-DNT	Multi-Task Deep Neural Network Wielozadaniowa sieć splotowa
NRZ	Non Return to Zero Kod bez powrotu do zera
NRZ-DPSK	Non Return to Zero Differential Phase Shift Keying Kod bez powrotu do zera z różnicową modulacją z kluczowaniem fazy
NRZ-DQPSK	Non to Return Zero Differential Quarternary Phase Shift Keying Kod bez powrotu do zera z różnicową kwadraturową modulacją z kluczowaniem fazy
NRZ-OOK	Non Return to Zero On-Off Keying Kod bez powrotu do zera z modulacją amplitudy
ONE	Optical Network Element Element sieci optycznej
OOK	On-Off Keying Modulacja amplitudy (w sieciach optycznych)
ORL	Optical Return Loss Tłumienie fali odbitej
OSI	Open System Interconnection Model odniesienia łączenia systemów otwartych
OPM	Optical Performance Monitoring Monitorowanie jakości optycznej
OSNR	Optical Signal to Noise Ratio Optyczny stosunek sygnał-szum

OTDR	Optical Time Domain Reflectometer Reflektometr optyczny
OXC	Optical Cross Connect Przełącznice optyczne
PAED	Parametric Asynchronous Eye Diagram Technika asynchronicznego wykresu oka
PAM	Pulse Amplitude Modulation Impulsowa modulacja amplitudy
PD	Photodiode Fotodioda
PDM-QPSK	Polarization Division Multiplexed Quadrature Phase-Shift Keying Modulacja gęstości impulsów z różnicowym kluczowaniem fazy
PMD	Polarization Mode Dispersion Dyspersja polaryzacyjna
PRBS	Pseudo Random Bit Sequence Pseudolosowa sekwencja bitów
PSK	Phase-Shift Keying Modulacja z kluczowaniem z przesuwem fazy
QAM	Quadrature Amplitude Modulation Kwadraturowa modulacja amplitudowo-fazowa
RBM	Restricted Boltzmann Machine Restrykcyjna maszyna Boltzmannna
ReLU	Rectifier Linear Unit Prosta liniowa funkcja aktywacji
ROADM	Reconfigurable Optical Add-drop Multiplexer Rekonfigurowalny multiplexer optyczny typu add-drop

RZ	Return to Zero Kod z powrotem do zera
RZ-DPSK	Return to Zero Differential Phase Shift Keying Kod z powrotem do zera z kwadraturową modulacją z kluczowaniem fazy
RZ-DQPSK	Return to Zero Differential Quaternary Phase Shift Keying Kod z powrotem do zera z różnicową kwadraturową modulacją z kluczowaniem fazy
RZ-OOK	Return to Zero On-Off Keying Kod z powrotem do zera z modulacją amplitudy
SBS	Stimulated Brillouin scattering Wymuszone rozpraszanie Brillouina
SLA	Service Level Agreement Umowa o gwarantowanym poziomie świadczenia usług
SNR	Signal to Noise Ratio Stosunek sygnał-szum
SPM	Self-phase Modulation Samo modulacja fazy
SRS	Stimulated Raman scattering Wymuszone rozpraszanie Ramana
SSE	Source Spontaneous Emission Szum pochodzący ze źródła światła
SVM	Support Vector Machine Maszyna wektorów nośnych
TDM	Time Division Multiplexing Multipleksowanie z podziałem czasu

TDNN	Time Delay Neural Networks Sieci neuronowe z opóźnieniem czasowym
UHD	Ultra High Definition Ultrawysoka rozdzielczość (3840x2160)
WDM	Wavelength Division Multiplexing Zwielokrotnienie w dziedzinie długości fali
XPM	Cross Phase modulation Skrótna modulacja fazy

1. Wprowadzenie i cel pracy

Stale postępujący rozwój technologii informatycznych oraz zwiększający się poziom cyfryzacji i informatyzacji w poszczególnych sektorach gospodarki na całym świecie spowodował ogromny wzrost zapotrzebowania na realizację usług multimedialnych nowej generacji wymagających dużych szybkości w transmisji danych. Telewizja HD (ang. *High Definition*) i UHD (ang. *Ultra High Definition*), usługi biznesowe, a także te łączące w jednym pakiecie Internet, telefon oraz radiofonię i telewizję wymagają zastosowania systemów teletransmisyjnych. Systemów wykorzystujących zaawansowane techniki modulacji, posiadających odpowiednie parametry pojemności (przepustowości), które są na bieżąco dostosowywane do konkretnych usług i klientów. Równocześnie od zarządców sieci i dostawców usług wymaga się zapewnienia rozwiązań o wysokim poziomie niezawodności pracy. Usługi powinny być odporne na awarie sprzętowe i świadczone na gwarantowanym poziomie SLA (ang. *Service Level Agreement*) m.in. w zakresie dostępności sieci, przepływności i jakości sygnału. Najnowocześniejszym medium transmisyjnym stosowanym w sieciach telekomunikacyjnych charakteryzującym się dużą przepustowością jest światłowód. Zgodnie z modelem OSI (ang. *Open System Interconnection*) stanowi on warstwę fizyczną w sieciach telekomunikacyjnych [1]. Aby sprostać współczesnym wymaganiom wykorzystuje się systemy, w których skład wchodzi elementy sieci takie jak rekonfigurowalne multipleksery optyczne typu add-drop ROADM (ang. *Reconfigurable Optical Add-drop Multiplexer*), optyczne przełącznice krzyżowe OXC (ang. *Optical Cross Connect*), a także przestrajalne lasery i filtry. Systemy te są oparte o coraz bardziej rozbudowaną architekturę kratową (ang. *mesh topology*) lub mieszaną pierścieniowo-kratową (ang. *ring-mesh topology*) [2]. Dla zapewnienia jak największej efektywności łączy optycznych stosuje się dodatkowe rozwiązania techniczne umożliwiające zwiększenie pojemności informacyjnej (jego przepustowości). Jednym z najważniejszych jest technika multipleksacji (z wielokrotnienia). Za najczęściej wykorzystywane techniki uznaje się wielokrotnienie falowe WDM (ang. *Wavelength Division Multiplexing*) oraz czasowe TDM (ang. *Time Division Multiplexing*), które są realizowane w sieciach dalekiego zasięgu, sieciach metropolitalnych oraz dostępowych.

Realizacja tak zaawansowanych systemów transmisji wprowadza dodatkowy poziom złożoności w warstwie fizycznej sieci optycznej i obniża transparentność w procesie jej zarządzania oraz zwiększa podatność na występowanie zakłóceń, ograniczających zdolności

systemów do przesyłania informacji. Na funkcjonowanie sieci i powstawanie błędów w trakcie transmisji mogą mieć wpływ różne zjawiska (np. tłumienie, dyspersja chromatyczna, szum wzmacnionej emisji spontanicznej, przenik i inne). Monitorując odpowiednie parametry transmitowanego sygnału można ocenić jakość transmisji oraz intensywność oddziaływania tych zjawisk. Od nowoczesnych metod monitorowania jakości optycznej OPM (ang. *Optical Performance Monitoring*) wymaga się wysokiej dokładności i dużego zakresu pomiarowego, szybkiego czasu wykonania pomiaru oraz wyznaczania parametrów mierzonych wielkości niezależnie od występujących zakłóceń lub innych niekorzystnych warunków pomiarowych. Kolejnym bardzo ważnym wymaganiem jest możliwość równoczesnego monitorowania wielu parametrów niezależnie od formatu modulacji oraz szybkości transmisji. Ponadto techniki takie powinny charakteryzować się małą złożonością układu, niskim zużyciem energii oraz możliwością zastosowania do pomiarów w czasie rzeczywistym.

Klasyczne metody, które opierają się na monitorowaniu pojedynczych zjawisk są za wolne i nie dostosowane do nowoczesnych wymagań oraz warunków pracy systemów transmisyjnych. Ich praktyczna implementacja wymagałaby wykorzystania wielu dedykowanych metod do konkretnego zjawiska, co byłoby zarówno nieekonomiczne, a także wpływałoby na większą złożoność i skomplikowanie układu monitorowania oraz większe zużycie energii. Wraz z rozwojem systemów transmisji optycznej opracowano kilka nowych metod przeznaczonych do równoczesnego monitorowania wybranych zjawisk za pomocą jednej techniki. Stworzone do tej pory metody nie spełniają jednak swojego zadania w warunkach rzeczywistych. Ich dokładność w wyznaczaniu wartości liczbowych parametrów opisujących dane zjawiska mocno spada w przypadku równoczesnego wystąpienia innych zjawisk. Dodatkowo metody takie charakteryzują się wąskim zakresem pomiarowym co oznacza, że ich zastosowanie jest ograniczone.

Nie ma zatem takich metod do równoczesnego monitorowania kilku zjawisk w ramach jednej metody, które byłyby dostosowane do bieżących systemów transmisji optycznej. Potrzeba opracowywania i wdrażania nowoczesnych technik monitorowania umożliwiających wyznaczanie wartości liczbowych mierzonych zjawisk z odpowiednią dokładnością doprowadziła do sformułowania **następującej tezy pracy**: *Problem monitorowania kilku, równocześnie występujących zjawisk zakłócających transmisję danych w światłowodzie może być efektywnie rozwiązany stosując metodę asynchronicznego próbkowania sygnałów i splotowe sieci neuronowe.*

Zasadniczym celem pracy jest udowodnienie postawionej tezy oraz opracowanie metody i schematu pomiarowego do jej realizacji, służącej wyznaczaniu wartości parametrów

opisujących zjawiska wpływające na jakość transmitowanego sygnału optycznego przy jednoczesnym ich występowaniu. Pomiar musi charakteryzować się małym błędem i ma odbywać się w warunkach równoczesnego występowania innych zjawisk w szerokim zakresie ich wartości, typowym dla rzeczywistych sieci optycznych.

Rozprawa doktorska składa się z siedmiu rozdziałów. W rozdziale nr 1 zaprezentowano problematykę będącą tematem badań oraz przedstawiono cel rozprawy doktorskiej. W rozdziale nr 2 omówiono zakłócenia w warstwie fizycznej sieci optycznej. W rozdziale nr 3 omówiono dostępne metody pomiaru jakości transmisji optycznej. W rozdziale nr 4 przedstawiono najważniejsze informacje o splotowych sieciach neuronowych. W rozdziale nr 5 omówiono proces uczenia sieci splotowej w wyniku, którego uzyskano gotowe modele przygotowane do wyznaczania wartości monitorowanych zjawisk. W rozdziale nr 6 przedstawiono wyniki badań wyznaczania wartości liczbowych monitorowanych zjawisk przy użyciu nauczonych gotowych modeli z wykorzystaniem dodatkowych portretów fazy. Rozdział 7 stanowi podsumowanie rozprawy doktorskiej.

2. Zakłócenia w warstwie fizycznej

Główne zjawiska zachodzące w warstwie fizycznej sieci optycznej powodujące ograniczenie zdolności systemów transmisji przedstawiono w zaleceniu ITU-T G.697 (11/2016) [3]. Według tego zalecenia dzieli się je na trzy grupy według kryterium częstości występowania. Za najczęściej występujące zjawiska uznaje się [3], [4], [5]: tłumienie, zmianę mocy kanału optycznego (pod wpływem zmiany wzmocnienia transmitowanego sygnału), odchylenie częstotliwości (długości fali) kanału optycznego od wartości nominalnej. Do zjawisk charakteryzujących się średnią częstotliwością występowania zalicza się: dyspersję polaryzacyjną PMD (ang. *Polarization Mode Dispersion*), mieszanie czterofalowe FWM (ang. *Four-Wave Mixing*), szum wzmocnionej emisji spontanicznej ASE (ang. *Amplified spontaneous emission*) pochodzący od wzmacniaczy optycznych, dyspersję chromatyczną CD (ang. *Chromatic Dispersion*), nachylenie charakterystyki dyspersji chromatycznej, odbicia, szum lasera, przenik międzykanałowy i interferometryczny. Ostatnią grupę stanowią zjawiska z małą częstotliwością występowania. Do tej grupy zalicza się: skrośną modulację fazy XPM (ang. *Cross-phase modulation*), samo modulację fazy SPM (ang. *Self-phase modulation*), stymulowane rozpraszanie Brillouina SBS (ang. *Stimulated Brillouin scattering*), stymulowane rozpraszanie Ramana SRS (ang. *Stimulated Raman scattering*). Wymienione zjawiska fizyczne poprzez swoje oddziaływanie wywierają wpływ na transmitowany sygnał powodując jego zniekształcenie. Z tego względu, w celu pełnego wykorzystania systemu transmisji optycznej oraz zapewnienia jego poprawnego funkcjonowania i wysokiej niezawodności działania konieczne jest stosowanie właściwych metod jego badania i utrzymania [2].

W rozprawie doktorskiej skupiono się na zjawiskach dyspersji chromatycznej, przeniku optycznego oraz szumie ASE. Zgodnie z wytycznymi ITU-T [3] są one jednymi z najważniejszych zjawisk do monitorowania o co najmniej średniej częstotliwości występowania, a ich równoczesne wystąpienie stanowi znaczący problem z punktu widzenia zapewnienia odpowiedniej jakości optycznej. Dyspersja chromatyczna to zjawisko liniowe, które dla małych przepływności można w prosty sposób kompensować. Zjawisko to może być jednak trudne do oszacowania w trakcie przełączania ruchu z powodu dynamicznie zmieniających się długości ścieżek tras optycznych w rekonfigurowalnych sieciach optycznych opartych o rozbudowaną architekturę kratową i pierścieniowo-kratową. Przenik jest parametrem jakości izolacji kanału optycznego, dlatego należy zwrócić na niego szczególną uwagę w systemach wykorzystujących technologię zwielokrotnienia. Wzmacniacze optyczne

są nieodłącznym elementem każdej sieci światłowodowej dalekiego zasięgu, a ich niestabilna praca może powodować nadmierną moc szumów w przesyłanym sygnale. Poniżej przedstawiono krótkie charakterystyki wybranych zjawisk [5], [6]:

a) Dyspersja Chromatyczna

Jest to jedno z głównych zjawisk ograniczających maksymalną prędkość oraz zasięg transmisji optycznej [7]. Budowa światłowodu jednomodowego powoduje, że przesyłany sygnał propaguje z różną prędkością, w zależności od długości fali. Właściwość ta wynika bezpośrednio z zależności współczynnika załamania światła od długości fali i powoduje rozmycie impulsu świetlnego, w dziedzinie czasu, w miarę propagowania w światłowodzie tworząc interferencję międzysymbolową. Rozmyty impuls nachodzi na sąsiednie przedziały bitowe powodując błędy w odbiorniku. W długich łączach dyspersja jest kompensowana poprzez wykorzystanie specjalnych modułów np. włókien kompensujących dyspersję DCF (ang. *Dispersion Compensating Fiber*) lub siatek Braga [8]. Pełna kompensacja w systemach wielofalowych (WDM) wymaga uwzględnienia nachylenia charakterystyki dyspersji. Nawet najmniejszy błąd w kompensacji dyspersji może mieć wpływ na moc sygnału, dlatego zmiany w akumulacji dyspersji powinny być monitorowane w kanale. W przypadku złej kompensacji może wystąpić dyspersja resztkowa, która również spowoduje rozmycie impulsu. Zjawisko dyspersji monitoruje się zazwyczaj dla prędkości 10 Gbit/s lub większej. Wartość dyspersji wyraża się w jednostce ps/nm.

b) Przenik optyczny (ang. *Optical Crosstalk*)

Zjawisko to polega na niepożądanym obecności energii sygnału w kanale optycznym z sąsiednich kanałów [9]. Można wyróżnić dwa typy zjawiska przeniku: wewnątrzkanałowy (interferometryczny) i międzykanałowy. Niedoskonałości w działaniu komponentów WDM takich jak przełącznice optyczne, multipleksery i filtry optyczne, mogą powodować zakłócenia w kanałach działających na tej samej długości fali. Sygnały interferencyjne, które mają taką samą długość fali (lub zbliżoną) co sygnał pożądanym powodują przenik wewnątrzkanałowy. W przeniku wewnątrzkanałowym, różnica długości fali pożądanego sygnału i sygnału przeniku mieści się w zakresie pasma elektrycznego odbiornika. Przenik w kanałach działających na różnych długościach fal nazywany jest przenikiem międzykanałowym. W tym przypadku długość fali sygnału przeniku różni się wystarczająco od pożądanego długości fali sygnału. Różnica w długości fali jest zwykle większa niż przepustowość elektryczna odbiornika, ale może też mieścić się w paśmie optycznym odbiornika.

Przenik jest jednym z głównych problemów występujących w technice WDM. Prawidłowo zaprojektowany demultiplekser ogranicza przenik do minimum, izolując kanał główny od kanałów sąsiednich. Przenik prowadzi do zmniejszenia stosunku sygnału do szumu i wzrostu elementowej stopy błędu. Wartość przeniku wyraża się w jednostce dB (decybel).

c) Szum ASE

Szum ten powstaje w trakcie emisji spontanicznej w każdym wzmacniaczu optycznym, obok pożądanej emisji wymuszonej [10], [11]. Miarą poziomu szumu ASE jest parametr Optycznego stosunku sygnał-szum OSNR (ang. *Optical Signal-Noise Ratio*). Szum ASE wpływa na pogorszenie wartości OSNR w łączach wykorzystujących wzmacniacze optyczne. Parametr OSNR jest wykorzystywany jako podstawowa metryka jakości sygnału w sieciach optycznych ze wzmocnieniem. Wartość OSNR wyraża się w jednostce dB (decybel). Istnieje również szum pochodzący ze źródła światła SSE (ang. *Source Spontaneous Emission*), jednak jest on pomijalnie mały. Z tego względu jedynym szumem optycznym brany pod uwagę jest ASE.

W tabeli 2.1 przedstawiono poziomy dokładności wybranych parametrów, które są wymagane od nowoczesnych metod monitorowania [12], [13]. Zostaną one wykorzystane na późniejszym etapie pracy do oceny dokładności wyznaczanych wartości liczbowych parametrów opisujących zjawiska zakłócające transmisję optyczną.

Tabela 2.1 Poziomy dokładności monitorowania wymagane przez OPM dla wybranych parametrów.

Monitorowany parametr	Wymagana dokładność
dyspersja chromatyczna	$< \pm 2\%$
OSNR, przenik	$< \pm 0,5 \text{ dB}$

Interpretację wartości w tab. 2.1 należy rozumieć następująco:

- $\pm 2\%$ oznacza, że różnica pomiędzy wartością dyspersji chromatycznej zmierzoną za pomocą opracowanej metody, a wartością referencyjną, powinna być mniejsza lub równa 2%.

Przykład: W światłowodzie na odcinku 65,5 km występuje dyspersja chromatyczna o wartości 140 ps/nm. Za pomocą opracowanej metody pomiarowej wyznaczono wartość dyspersji o wartości 142,35 ps/nm. W tym przypadku 2% wartości względem wartości referencyjnej wynosi 2,8 ps/nm. Uzyskana różnica wartości między tą wyznaczoną, a obecną w światłowodzie wynosi 2,35 ps/nm. Wartość ta jest mniejsza

lub równa od 2% (tj. 2,8 ps/nm), zatem zachowana jest wymagana dokładność metody monitorowania.

- $\pm 0,5$ dB oznacza, że różnica pomiędzy wartością OSNR (lub przeniku optycznego) zmierzoną za pomocą opracowanej metody, a wartością referencyjną, powinna być mniejsza lub równa 0,5 dB.

3. Metody pomiaru jakości transmisji optycznej

Stosowane są różne klasyfikacje metod umożliwiających pomiar jakości transmisji optycznej. W zaleceniu ITU-T G.697 przedstawiono ogólny podział na sześć równorzędnych kategorii [3]. Jakość sygnału można monitorować w dziedzinie czasu i częstotliwości. Pomiar taki nie mierzą każdego pojedynczego zjawiska powodującego zakłócenia transmisji, lecz wpływ tych zakłóceń na parametry, które można zmierzyć (np. wykres oczkowy). Kolejnym sposobem podziału metod pomiarowych jest spojrzenie na to co jest analizowane. Pomiar jakości może sprowadzać się do kontroli pracy urządzeń wchodzących w skład sieci optycznej. Wykorzystuje się tu korelację pomiędzy uszkodzeniami elementów składowych systemu transmisyjnego, a jakością transmitowanego sygnału. Zakłada się, że jakość sygnału ulega degradacji, gdy parametry sprzętu są poza określonymi, ściśle zdefiniowanymi zakresami pracy. Jest to metoda pośrednia. Jakość transmisji sygnału może być również mierzona poprzez monitorowanie łącza światłowodowego. Zastosowanie reflektometru optycznego OTDR (ang. *Optical Time Domain Reflectometer*) pozwala na wykrycie i zlokalizowanie uszkodzenia łącza światłowodowego np. z powodu przecięcia lub zbyt wysokiego tłumienia (więcej informacji o OTDR zamieszczono w podrozdziale 3.1.2). Inny podział metod pomiarowych opiera się na tym czy urządzenie pomiarowe jest czy też nie jest elementem wbudowanym w system transmisyjny. Do pomiaru jakości można również wykorzystać wbudowany sprzęt monitorujący. Sprzęt wbudowany jest zwykle ściśle zintegrowany z funkcjami zarządzania elementu sieci optycznej ONE (ang. *Optical Network Element*). Ze względu na koszty, wbudowany monitoring jest stosowany w ograniczonym zakresie, zwykle do pojedynczych parametrów np. wejściowej mocy optycznej sygnału. Ostatnim sposobem na pomiar jakości sygnału przedstawionym w zaleceniach ITU-T jest wykorzystanie zewnętrznego sprzętu monitorującego. Sprzęt taki jest zwykle używany do mierzenia dodatkowych parametrów wydajności lub gdy wymagana jest dokładniejsza wartość niektórych parametrów. Głównym zastosowaniem jest lokalizacja trudnych do wykrycia awarii, których nie można wyizolować za pomocą wbudowanych urządzeń monitorujących, a także testy funkcjonalne i dokładne pomiary parametrów podczas instalacji, rozruchu lub naprawy. Zewnętrzne urządzenia monitorujące są podłączane na żądanie do krytycznych segmentów sieci.

Inna metoda badania jakości systemów transmisji optycznej ze zwielokrotnieniem przedstawiona w [2] zakłada, że monitorowanie może odbywać się w warstwie transmisyjnej, optycznej oraz multipleksacyjnej. Badanie w warstwie transmisyjnej ma na celu określenie

jakości transmisji sygnałów cyfrowych, poprzez określenie poziomu występowania błędów w transmisji. Jakość transmisji danych sprawdzana jest głównie poprzez wykonanie pomiaru elementowej stopy błędów BER (ang. *Bit Error Rate*) określającej iloraz liczby błędnie odebranych bitów względem liczby wszystkich odebranych bitów oraz analizy wykresu oczkowego z użyciem tzw. masek telekomunikacyjnych. Możliwy jest również pomiar elektrycznego stosunku sygnału do szumu (parametr Q) oraz szybkozmiennej fluktuacji fazy (ang. *Jitter*, drgania zboczy sygnału) [2]. Badanie jakości sygnału w warstwie optycznej polega na pomiarze określonych parametrów optycznych w wyznaczonych punktach styku systemu. Pomiar mają na celu uzyskanie informacji na temat parametrów [2]: źródeł światła (moc optyczna, parametry widmowe), krotnic falowych (tłumienie i reflektancja krotnicy, przenik międzykanałowy, parametry widmowe: szerokość pasma; wartość szczytowa; środkowa długość fali; wpływ polaryzacji światła na parametry widmowe), wzmacniaczy optycznych (wzmocnienie, skrośne nasycenie wzmocnienia, płaskość charakterystyki wzmocnienia, poziom szumu emisji spontanicznej) i toru światłowodowego (tłumienie sygnału poprzez tor światłowodowy, tłumienie fali odbitej, dyspersję chromatyczną i polaryzacyjną). Warstwę multipleksacyjną wyodrębnia się w systemach ze zwielokrotnieniem falowym, które są rekonfigurowane na poziomie optycznym. W systemach tych wykorzystuje się optyczne krotnice transferowe. Badając jakość sygnału w tej warstwie należy zwrócić uwagę przede wszystkim na następujące parametry krotnic [2]: poziom mocy optycznej sygnału po multipleksacji i demultipleksacji, poziom mocy optycznej kanału wprowadzanego i wydzielanego oraz przenik międzykanałowy i interferometryczny.

W dalszej części rozprawy opisano najczęściej wykorzystywane metody pomiaru jakości transmisji sygnału w optycznych sieciach telekomunikacyjnych. W podrozdziale 3.1 omówiono metody pomiaru jakości sygnału optycznego, natomiast w podrozdziale 3.2 sygnału elektrycznego.

3.1 Metody pomiaru jakości sygnału optycznego

Jakość sygnału w warstwie optycznej można mierzyć w sposób aktywny oraz bierny. Pomiar aktywny systemu transmisyjnego przeprowadza się przed jego włączeniem do pracy w sieci telekomunikacyjnej. Pomiar bierny wykonuje się w następnej kolejności. Jego głównym celem jest kontrola parametrów jakościowych transmisji, w celu reagowania na występujące zakłócenia.

3.1.1 Pomiar aktywny

Pomiar powinien obejmować sprawdzenie zgodności wszystkich parametrów elementów składowych systemu z normami i zaleceniami, a także sprawdzenie poprawności współpracy poszczególnych części składowych (nadajniki, odbiorniki, krotnice falowe, multipleksery, demultipleksery, wzmacniacze itd.). Pomiar aktywny ma na celu uzyskanie informacji nt. parametrów [2]:

a) Źródła światła

W celu analizy pracy nadajników wykonuje się pomiary mocy optycznej oraz parametrów widmowych. Pomiar mocy można wykonać za pomocą miernika mocy optycznej lub analizatora widma. Do parametrów widmowych zalicza się długość fali oraz szerokość widmową. Można je wyznaczyć za pomocą analizatora wykorzystując przebiegi ich widm.

b) Multiplekser/demultiplekser

Do parametrów określających pracę krotnic falowych zalicza się: tłumienie i reflektancję, przenik międzykanałowy, parametry widmowe (średkowa długość fali, wartość szczytowa, szerokość pasma) oraz wpływ polaryzacji światła na parametry widmowe. Wymienione parametry mierzy się podczas badania multipleksera oraz demultipleksera w systemach ze zwielokrotnieniem. Układy pomiarowe w zależności od mierzonego parametru oparte są o miernik mocy optycznej lub analizator widma.

c) Wzmacniaczy optycznych

Podstawowymi parametrami mierzonymi we wzmacniaczach światłowodowych są: wzmocnienie, skrośne nasycenie wzmocnienia oraz płaskość charakterystyki wzmocnienia, które odpowiadają bezpośrednio za wzmocnienie sygnału. Dodatkowo należy badać poziom szumu emisji spontanicznej. W celu pomiaru parametrów dotyczących wzmocnienia należy wykorzystać układ pomiarowy oparty o miernik mocy optycznej lub analizator widma. Do wyznaczenia poziomu szumu ASE należy w układzie pomiarowym wykorzystać analizator widma oraz jedną z następujących metod: interpolacyjną, aproksymacyjną, wygaszania w dziedzinie czasu lub zastępowania badanego kanału [2].

d) Toru światłowodowego

Głównym celem badania toru światłowodowego jest określenie wpływu medium transmisyjnego na jakość transmisji. Do głównych parametrów pomiarowych zalicza się: tłumienie sygnału, tłumienie fali odbitej ORL (ang. *Optical Return Loss*), dyspersję

chromatyczną, dyspersję polaryzacyjną. Aby wyznaczyć tłumienie we włóknie optycznym wykorzystuje się reflektometr. Tłumienie fali odbitej można wyznaczyć na dwa sposoby: z wykorzystaniem przestrajalnego źródła światła i miernika mocy oraz przy pomocy szerokopasmowego źródła światła i analizatora widma optycznego. W celu pomiaru dyspersji chromatycznej można wykorzystać metodę różnicy czasu propagacji oraz reflektometr światłowodowy. Dostępne są też inne podejścia np. metoda wykorzystująca modulację z przesunięciem fazy czy wykorzystująca różnicowe przesunięcie fazy. Pomiar dyspersji polaryzacyjnej można wykonać za pomocą różnych metod np.: opartej na analizie macierzy Jonesa, wykorzystującej sferę Poincarego czy interferometrycznej [2].

3.1.2 Pomiar bierny

Po przeprowadzeniu pomiaru aktywnego i pełnym uruchomieniu systemu możliwe jest przejście do pomiaru biernego, czyli monitorowania wybranych parametrów systemu optycznego w trakcie transmisji. Proces monitorowania jakości sygnału można podzielić na następujące kategorie [2]:

a) Monitorowanie infrastruktury łącza światłowodowego

Do pomiaru parametrów infrastruktury światłowodowej wykorzystuje się specjalne urządzenie zwane reflektometrem optycznym. Pozwala ono na pomiar [14]:

- wartości tłumienia całego traktu światłowodowego,
- wartości tłumienia poszczególnych odcinków traktu,
- wartości tłumienia wprowadzanego przez połączenia rozłączne i spawane (trwałe),
- długości optycznej światłowodu,
- reflektancji złączy.

Dodatkowo reflektometr pomaga w lokalizacji uszkodzeń oraz ich klasyfikacji (zgięcie, pęknięcie, zerwanie).

b) Monitorowanie parametrów sygnału optycznego

Aby monitorować cały system optyczny w sposób praktyczny i efektywny należy wziąć pod uwagę najważniejsze parametry, do których zalicza się [2], [15]:

- całkowitą moc optyczną w światłowodzie,
- poziom mocy optycznej w kanale,

- częstotliwość środkową (środkową długość fali) kanału,
- odległość między kanałami,
- odchylenie częstotliwości środkowej (środkowej długości fali) kanału,
- optyczny stosunek sygnału do szumu.

Pomiar poszczególnych parametrów sygnału optycznego można przeprowadzić z wykorzystaniem: miernika mocy optycznej, analizatora widma optycznego lub miernika długości fali.

c) Monitorowanie wzmacniacza optycznego

Monitorowanie pracy wzmacniacza optycznego np. typu EDFA (ang. *Erbium-Doped Fiber Amplifier*) można przeprowadzić metodami [2], [16]:

- Monitorowania całkowitej mocy optycznej na wejściu i wyjściu wzmacniacza,
- Monitorowania mocy optycznej w jednym kanale na wejściu i wyjściu wzmacniacza,
- Monitorowania mocy optycznej we wszystkich kanałach na wejściu i wyjściu wzmacniacza,
- Monitorowania sygnału pompy optycznej.

Dla zaawansowanych systemów ze zwielokrotnieniem falowym najbardziej wskazana jest metoda monitorowania mocy optycznej we wszystkich kanałach na wejściu i wyjściu wzmacniacza.

W podrozdziale 3.2 przedstawiono wybrane metody pomiaru jakości sygnału elektrycznego.


3.2 Metody pomiaru jakości sygnału elektrycznego

W rozprawie doktorskiej skoncentrowano się na analizie metod do pomiaru jakości sygnału po detekcji na elektryczny. Klasyczne metody nie pozwalały na jednoczesne monitorowanie wielu zjawisk za pomocą jednej metody, dlatego w celu równoczesnego pomiaru różnych parametrów sygnału opisujących zjawiska, konieczne było wykorzystanie kilku dedykowanych technik dla każdego parametru z osobna. Wykorzystanie równocześnie wielu technik wprowadzałoby jednak większą złożoność systemu pomiarowego i zwiększało koszty jego działania. Dodatkowo techniki takie musiały się charakteryzować odpornością na oddziaływanie innych równocześnie występujących zaburzeń w trakcie wykonywania pomiarów. Innymi słowy: powinny umożliwiać pomiar monitorowanego parametru bez zafałszowania wyniku odczytanej wartości spowodowanej obecnością innego zjawiska.

Wraz z rozwojem sieci optycznych o dużych przepływnościach wprowadzono transmisje wielokanałowe i nowe formaty modulacji, zwiększyły się również wymogi dotyczące szybkiej rekonfiguracji sieci. Dodatkowo nastąpił wzrost zapotrzebowania na uniwersalne i szybkie metody do oceny jakości transmisji optycznej, które umożliwiłyby uzyskać (przy pomocy jednej metody) jak najwięcej informacji o ewentualnych wielu możliwych przyczynach pogorszenia jakości transmisji. Z tego powodu bardzo ważnym kierunkiem w rozwoju monitorowania jakości sieci optycznych stały się techniki umożliwiające równoczesny pomiar kilku parametrów sygnału przy pomocy jednej metody. W podrozdziałach 3.2.1 – 3.2.6 przedstawiono najbardziej popularne metody elektryczne.

3.2.1 Wykres oczkowy

Wykres oczkowy stanowi jedną z podstawowych technik oceny jakości transmisji [4], [17], [18]. Powstaje poprzez nałożenie na siebie przebiegów sygnału zawierających wszystkie możliwe kombinacje odebrany zer i jedynek w danym oknie czasowym. Na rys. 3.1. przedstawiono przykładowy wykres oczkowy z zaznaczonymi mierzalnymi parametrami [19].



Rys. 3.1 Wykres oczkowy z zaznaczonymi mierzalnymi parametrami.

Szerokość wykresu służy do określenia przedziału czasu, w którym należy próbkować sygnał, aby uniknąć ryzyka interferencji międzysymbolowej, która może powodować błędy odbioru. Maksymalna rozwartość sygnału (będąca różnicą pomiędzy minimalną i maksymalną amplitudą sygnału) jest parametrem wrażliwym na szum oraz zniekształcenia sygnału i zmniejsza się wraz ze wzrostem wartości wspomnianych zakłóceń. Odporność systemu na szumy określa margines szumowy. Nachylenie wykresu określa podatność na błędy czasowe. Im mniejsze jest nachylenie, tym większe prawdopodobieństwo wystąpienia błędu odbioru. Na podstawie zniekształcenia czasowego przecięcia wykresu oka określa się parametr jitter

(szybko zmienna fluktuacja fazy). Jitter powstaje w wyniku zniekształceń sygnału spowodowanych przez zjawiska: nieliniowe, dyspersję chromatyczną i polaryzacyjną oraz szумы w odbiorniku. Współczynnik ekstynkcji definiuje się jako stosunek średniej wartości amplitudy maksymalnej oraz minimalnej. Do oceny jakości sygnału wykorzystuje się pochodzące z wykresu oczkowego parametry najmniejszej i największej amplitudy oraz czas i amplitudę przecięcia przebiegów. Aby w sposób bezpośredni wyznaczyć jakość sygnału oblicza się parametr Q (elektryczny stosunek sygnału do szumu) [17], [18]:

$$Q = \frac{U_1 - U_0}{\sigma_1 + \sigma_0} \quad (3.1)$$

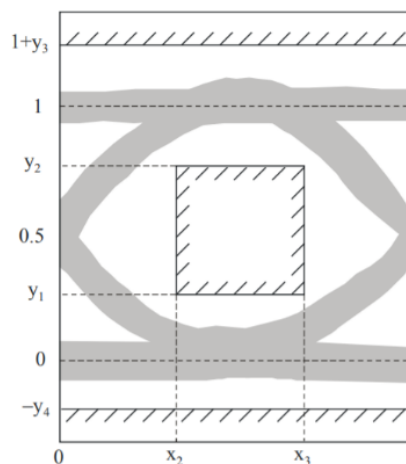
gdzie: U_1 i U_0 - wartość średnia sygnału dla amplitudy maksymalnej i minimalnej, σ_1 i σ_0 to odchylenie standardowe wartości sygnału dla amplitudy maksymalnej i minimalnej.

Mając do dyspozycji wartość parametru Q można obliczyć chwilową wartość elementowej stopy błędu [17]:

$$BER = \frac{1}{2} \left[erf * \left(\frac{Q}{\sqrt{2}} \right) \right] \quad (3.2)$$

gdzie: erf to funkcja błędu, a znak „*” oznacza splot.

Należy podkreślić, że wyznaczenie wartości BER na podstawie parametru Q, nie zastępuje pomiaru elementowej stopy błędu [20]. Analizę wykresu oczkowego, można zautomatyzować poprzez zastosowanie specjalnej maski [21]. W celu oceny jakości nadawanego sygnału należy brać pod uwagę przede wszystkim otwarcie oka. Gdy przebieg sygnału nie przecina któregokolwiek z kreskowanych obszarów to jakość sygnału jest na odpowiednim poziomie. Na rys. 3.2 zaprezentowano maskę oka dla kodowania NRZ (ang. *Non Return to Zero*).




Rys. 3.2 Maska oka [21].

Parametry określające właściwości maski (x_2 , x_3 , y_1 , y_2 , y_3 , y_4) dla różnych formatów transmitowanych sygnałów są dostępne w zaleceniach ITU-T; np. w [21].

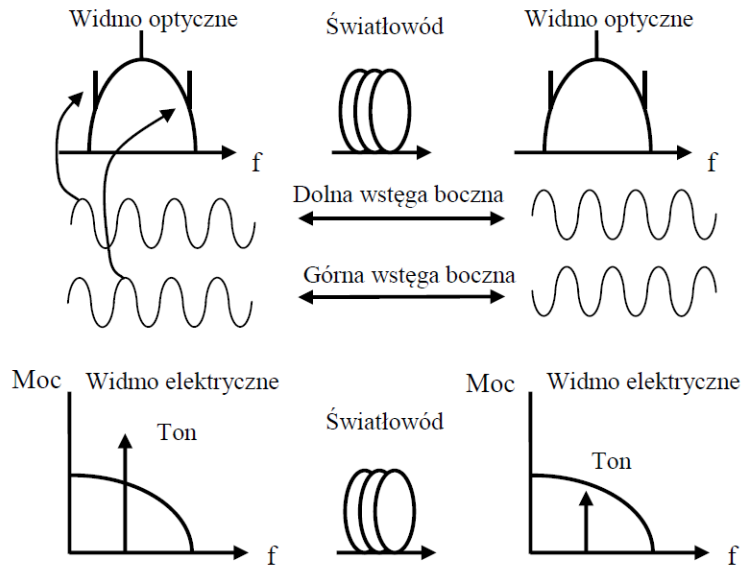
3.2.2 Metoda oparta o monitorowanie podnośnej sygnału

Technika monitorowania podnośnej sygnału [22], [23] polega na monitorowaniu poziomu mocy widma sygnału w miejscach, gdzie nie są transmitowane dane. Możliwe jest monitorowanie niskich lub wysokich częstotliwości w zakresie pasma kanału. Technika ta wykorzystuje sygnał (ton) o wąskim widmie zmodulowanym amplitudowo. Na rys. 3.3 przedstawiono sposób dodania tonu (którego częstotliwość znajduje się wewnątrz pasma danych sygnału) do pasma sygnału na podnośnej.



Rys. 3.3 Sposób dodania tonu do pasma sygnału na jego podnośnej.

Wartość poziomu mocy tonu jest proporcjonalna do wartości mocy optycznej w kanale. Ton dodany na podnośnej podlega tak jak cały sygnał zjawiskom dyspersyjnym. Z tego względu technika ta może być wykorzystywana do monitorowania zjawisk dyspersji chromatycznej i polaryzacyjnej. Opisana metoda opiera się na efekcie zaniku mocy tonu dodanego w paśmie kanału z powodu występującej dyspersji chromatycznej. Tony dodane na górnej i dolnej wstędze bocznej są oddalone od częstotliwości nośnej sygnału w równej odległości i jako sygnały w nadajniku w dziedzinie czasu znajdują się w fazie. W trakcie transmisji ich fazy ulegają przesunięciu z powodu zjawiska dyspersji chromatycznej. Stopień przesunięcia fazowego jest zależny od wartości nagromadzonej dyspersji chromatycznej. Podnośna detekowana w fotodetektorze ulega zanikowi wraz ze wzrostem przesunięcia fazowego pomiędzy wstęgami bocznymi. Zostało to zobrazowane na rys. 3.4.



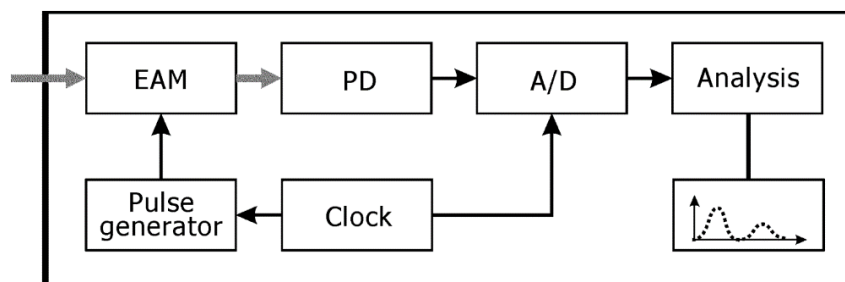
Rys. 3.4 Sposób zanikania tonu w wyniku oddziaływania dyspersji chromatycznej [19].

Wpływ zjawiska dyspersji polaryzacyjnej na detekcję sygnału w odbiorniku i zanik mocy w podnośnej jest podobny jak dla dyspersji chromatycznej. Aby uwydatnić wpływ dyspersji polaryzacyjnej konieczne jest wyeliminowanie wpływu dyspersji chromatycznej. Można tego dokonać poprzez zastosowanie filtra optycznego o bardzo wąskim paśmie, którego częstotliwość środkowa będzie ustawiona na częstotliwość jednej z wstęg bocznych. Działanie filtra spowoduje zniwelowanie wpływu dyspersji chromatycznej i uwydatnienie wpływu dyspersji polaryzacyjnej w postaci zaniku mocy tonu. Omawiana metoda została zademonstrowana w pracy [22], gdzie pozwoliła na monitorowanie dyspersji chromatycznej w zakresie od 0 do 675 ps/nm dla częstotliwości tonu 7 GHz, od 0 do 975 ps/nm dla częstotliwości tonu 8 GHz, od 0 do 1200 ps/nm dla częstotliwości tonu 9 GHz dla szybkości transmisji 10 Gbit/s oraz parametru różnicowego opóźnienia grupowego DGD (ang. *Differential Group Delay*) opisującego zjawisko dyspersji polaryzacyjnej w zakresie od 0 do 15 ps niezależnie od tonu.

3.2.3 Technika asynchronicznego histogramu amplitudy


Technika asynchronicznego histogramu amplitudy AAH (ang. *Asynchronous Amplitude Histogram*) [24], [25], [26] pozwala na monitorowanie zjawisk dyspersji chromatycznej i polaryzacyjnej, a także szumu wzmocnionej emisji spontanicznej. Jej najważniejszą zaletą jest asynchroniczność, dzięki czemu nie ma potrzeby odzyskiwania synchronizacji zegara. Histogram budowany jest z próbek sygnału pobranych w sposób asynchroniczny. Próbkę kształtu fali optycznej wykorzystane do budowy asynchronicznego histogramu amplitudy,

pozyskiwane są w następujący sposób: schemat pomiarowy metody AAH (rys. 3.5) wykorzystuje wewnętrzny zegar (ang. *Clock*), który jest niezależny od zegara przychodzącego sygnału. Zegar wykorzystywany jest przez generator impulsów elektrycznych (ang. *Pulse generator*), który z kolei stymuluje modulator EAM (ang. *Electro-absorption modulator*). Fala optyczna jest generowana w ciąg impulsów w takt częstotliwości wewnętrznego zegara. Natężenie impulsów jest proporcjonalne do chwilowej mocy sygnału optycznego. Impulsy optyczne są przetwarzane na impulsy elektryczne przez fotodiodę PD (ang. *Photodiode*), a wartość odbieranej mocy określana jest w przetworniku analogowo-cyfrowym A/D. Zbierane wartości tworzą asynchroniczny histogram amplitudy.



Rys. 3.5 Generowanie próbek sygnału fali optycznej wykorzystanych do budowy histogramu.

Na końcu stworzony histogram jest analizowany przez specjalny algorytm specyficzny dla każdego formatu modulacji [26]. Badane parametry opisujące monitorowane zjawiska określone są na podstawie statystycznych właściwości rozkładu amplitudy sygnału przedstawionych na histogramie. Na rys. 3.6 przedstawiono przykładowy histogram otrzymany metodą AAH dla sygnału z modulacją RZ-DPSK.



Rys. 3.6 Przykładowy histogram prezentowanej metody dla sygnału RZ-DPSK [24].

Wartość współczynnika dyspersji chromatycznej i parametru OSNR oblicza się na podstawie wartości położenia charakterystycznych wierzchołków zaznaczonych na histogramie (czarne grube strzałki). Aby obliczyć wartość współczynnika dyspersji chromatycznej należy skorzystać ze wzoru [27]:

$$CD = \frac{\mu_1 - \mu_2}{\mu_m} \quad (3.3)$$

gdzie: μ_m - średnia arytmetyczna poziomu sygnału, μ_1 i μ_2 - odpowiednio wartości dla stanu wysokiego i niskiego sygnału.

Wartość parametru stosunek sygnał/szum (ang. *Signal to Noise Ratio*, SNR) w paśmie elektrycznym [28] można obliczyć ze wzoru:

$$F_{SNR} = \frac{N_1}{N_m} \quad (3.4)$$

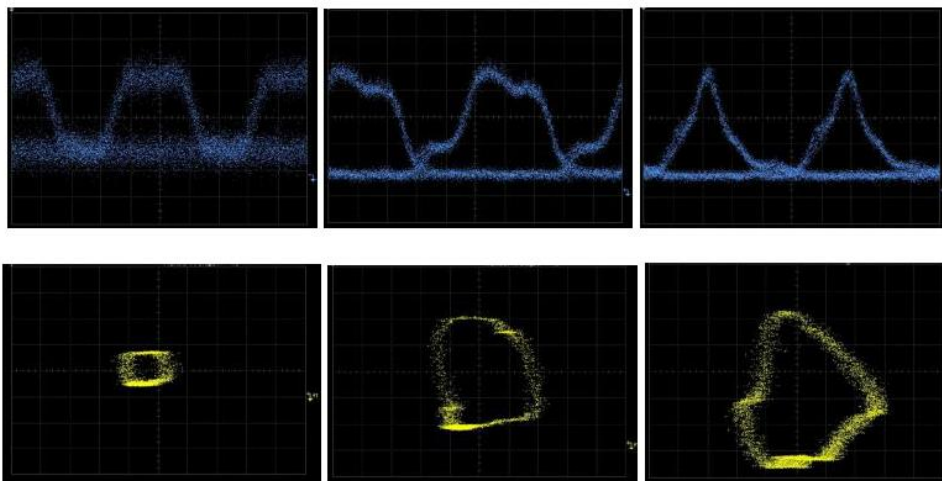
gdzie: N_1 - wysokość wierzchołka histogramu dla stanu wysokiego sygnału, N_m - wysokości histogramu dla średniego poziomu sygnału.

Zmiana wysokości wierzchołka na histogramie, odpowiada zmianom poziomu szumu ASE w sygnale optycznym, dlatego współczynnik F_{SNR} pozwala na wyznaczenie wartości OSNR. Metoda może być wykorzystywana do oceny jakości transmisji z modulacją DPSK i OOK (ang. *On-Off Keying*). Działanie metody zademonstrowano w pracy [24]. Dla transmisji 10 Gbit/s NRZ-DPSK (ang. *Non Return to zero - Differential Phase Shift Keying*) zakres monitorowania zjawiska dyspersji chromatycznej wynosił od -600 do 450 ps/nm, natomiast OSNR od 22 do 38 dB. W przypadku transmisji 10 Gbit/s RZ-DPSK zakres mierzalności dyspersji chromatycznej wynosił od -600 do 480 ps/nm, a OSNR od 17 do 27 dB. Dla transmisji 20 Gbit/s CSRZ-DPSK (ang. *Carrier-Suppressed Return to zero - Differential Phase Shift Keying*) uzyskano zakres mierzalności dyspersji chromatycznej od -150 do 150 ps/nm oraz OSNR od 16 do 40 dB, natomiast dla 20 Gbit/s RZ-DQPSK (ang. *Return to zero - Differential Quaternary Phase Shift Keying*) pomiar dyspersji chromatycznej był możliwy od -550 do 400 ps/nm, a dla OSNR od 17 do 39 dB.

3.2.4 Parametryczny asynchroniczny wykres oka

Technika asynchronicznego wykresu oka PAED (ang. *Parametric Asynchronous Eye Diagram*) została zaprezentowana w [29], [30] i może być wykorzystywana do monitorowania zjawisk dyspersji chromatycznej i polaryzacyjnej oraz szumu ASE. Transmitowany sygnał zostaje

przed odbiornikiem rozdzielony na dwie linie. Poprzez pierwszą z nich trafia do modułu różniczkującego [31], [32] w którym jest po sprzęgnięciu z dodatkowym źródłem światła podany na wzmacniacz optyczny i poprzez optyczny filtr Gaussa trafia do pierwszego fotodetektora. Sygnał z drugiej linii bezpośrednio trafia do fotodetektora. Następnie z sygnałów elektrycznych tworzone są wykresy punktowe (współrzędna X – sygnał z linii modułu różniczkującego, współrzędna Y – sygnał z drugiej linii), które przyjmują różne kształty w zależności od występujących zakłóceń. Na rys. 3.7 zamieszczono przykładowe charakterystyki przedstawiające w kolejnych kolumnach zjawiska szumu ASE, dyspersji polaryzacyjnej i chromatycznej (dolne wykresy) dla przepływności 20 Gbit/s i odpowiadające im wykresy oka dla kodu RZ (ang. *Return to Zero*) (górny wykres).

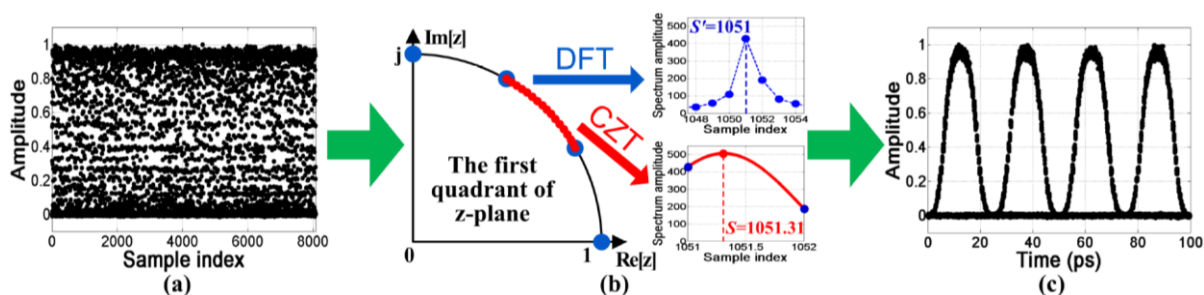


Rys. 3.7 Wykresy przedstawiające wpływ poszczególnych zjawisk na kształt wykresów [29].

Każde ze zjawisk ma inny wpływ na kształt wykresu. W celu wyznaczenia wartości liczbowych parametrów opisujących zjawiska, uzyskane obrazy należy poddać dalszej analizie wykorzystując np. algorytmu uczenie maszynowego. Działanie metody PAED zademonstrowano w pracach [29], [30]. Wykorzystano ją dla transmisji 10 Gbit/s RZ-OOK (ang. *Return to Zero On-Off Keying*) do monitorowania dyspersji chromatycznej od 0 do 200 ps/nm, DGD od 0 do 10 ps oraz OSNR od 10 do 28 dB, dla transmisji 10 Gbit/s NRZ-OOK (ang. *Non Return to Zero On-Off Keying*) dyspersję chromatyczną od 0 do 800 ps/nm, DGD od 0 do 20 ps oraz OSNR od 10 do 28 dB. Dla 20 Gbit/s RZ-OOK, dyspersję chromatyczną zmierzono w zakresie od 0 do 100 ps/nm, DGD od 0 do 5 ps, a OSNR od 10 do 28 dB, natomiast dla 20 Gbit/s NRZ-OOK dyspersję chromatyczną od 0 do 200 ps/nm, DGD od 0 do 10 ps oraz OSNR od 10 do 28 dB. Dla transmisji 20 Gbit/s RZ zmierzono zakres monitorowania dyspersji chromatycznej od 0 do 170 ps/nm, DGD od 0 do 30 ps oraz OSNR od 10 do 24 dB.

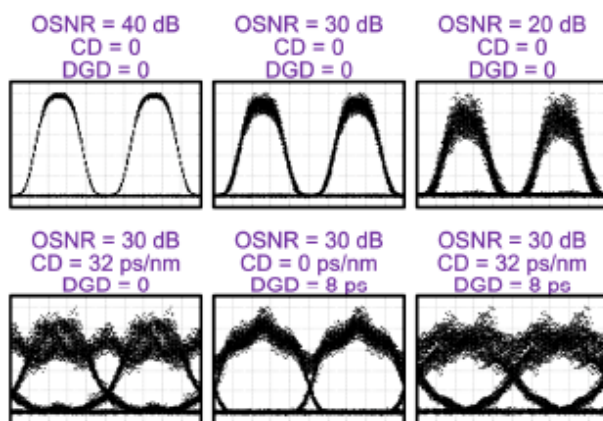
3.2.5 Technika monitorowania parametrów z zrekonstruowanego wykresu oczkowego

Technika monitorowania parametrów z zrekonstruowanego wykresu oczkowego (*ang. Reconstructed eye diagram*) polega na programowej rekonstrukcji wykresu oczkowego z wykorzystaniem specjalnego algorytmu opartego o dyskretną transformatę Fouriera DFT (*ang. Discrete Fourier Transform*) oraz transformatę świergotową CZT (*ang. Chirp Z-transform*). Proces rekonstrukcji rozpoczyna się po przejściu sygnału przez fotodetektor i asynchronicznym próbkowaniu [33]. Następnie dane trafiają do autorskiego algorytmu CZT-SS (*ang. Chirp-z Transform Software Synchronization*) [34], [35], który w wyniku użycia kolejno DFT i CZT rekonstruuje wykres oczkowy. Na rys. 3.8 przedstawiono etapy rekonstrukcji wykresu oczkowego.



Rys. 3.8 Wykres przedstawiający rekonstrukcję sygnału, a) sygnał uzyskany w fotodetektorze i po próbkowaniu, b) zastosowanie algorytmu CZT-SS, c) uzyskany zrekonstruowany wykres oka [36].

Kształt uzyskanego wykresu oczkowego zależy od występujących zjawisk fizycznych ograniczających jakość transmisji (rys. 3.9). Z wykresów tych trudno jest bezpośrednio odczytać wartości liczbowe parametrów opisujących zjawiska. Aby uzyskać takie wartości dane tworzące charakterystyki należy poddać dalszej analizie z wykorzystaniem dodatkowych technik np. uczenia maszynowego [37].




Rys. 3.9 Przykładowe zrekonstruowane wykresy oka, z różnymi wartościami zakłóceń [36].

Przykład wykorzystania tej metody pokazano w pracy [36]. Zastosowano ją do monitorowania zjawisk dyspersji chromatycznej w zakresie od 0 do 32 ps/nm, parametru DGD w zakresie od 0 do 8 ps oraz OSNR w zakresie od 20 do 40 dB dla przepływności 40 Gbit/s i modulacji RZ-OOK.

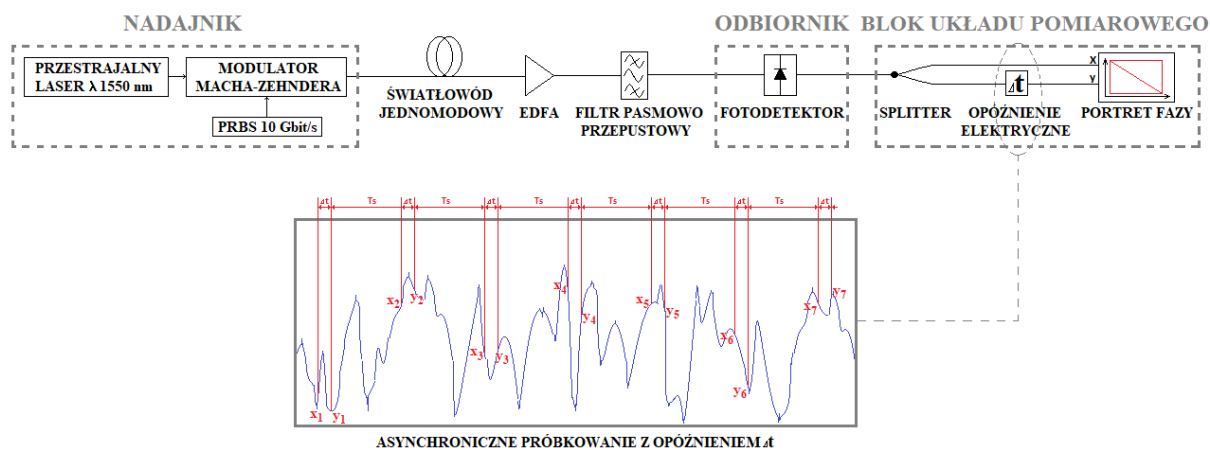
3.2.6 Asynchroniczne próbkowanie z opóźnieniem

Technika Asynchronicznego próbkowania z opóźnieniem ADTS (ang. *Asynchronous Delay Tap-Sampling*) umożliwia bezpośredni pomiar zakłóceń sygnału bez konieczności odzyskiwania synchronizacji zegara [38], [39], [40]. Metoda może być wykorzystana do monitorowania zjawisk dyspersji chromatycznej i polaryzacyjnej, szumu ASE, przeniku optycznego. Dodatkowo metodę można stosować dla różnych formatów modulacji i prędkości transmisji. Z przykładową demonstracją metody ADTS można się zapoznać w [38], [39], [40]. Dla transmisji 10 Gbit/s RZ-DPSK i NRZ-DPSK zmierzono dyspersję chromatyczną w zakresie od -720 do 800 ps/nm, parametr DGD od 0 do 40 ps, OSNR od 15 do 35 dB oraz przenik optyczny dla -25 dB. Na rys. 3.10 zamieszczono przykładowe wykresy oczkowe (pierwszy wiersz) i odpowiadające im portrety fazy (drugi wiersz) kolejno dla sygnału czystego (niezakłóconego), zakłóconego zjawiskami: szumu ASE, dyspersji chromatycznej i polaryzacyjnej, przeniku optycznego oraz wszystkich zjawisk równocześnie (ostatnia kolumna).




Rys. 3.10 Wpływ różnych zjawisk na kształt wykresów punktowych dla prędkości transmisji 40 Gbit/s, formatu modulacji NRZ-DPSK i opóźnienia 1 bit [13].

Schemat ideowy metody pomiarowej ADTS wraz z przebiegiem czasowym obrazującym sposób próbkowania sygnału został przedstawiony na rys. 3.11. Sygnał po detekcji zostaje w splitterze rozdzielony do dwóch linii transmisyjnych. Jedna z linii w sposób kontrolowany wprowadza zadane opóźnienie Δt . W ostatnim etapie następuje proces próbkowania sygnału.



Rys. 3.11 Schemat ideowy metody ADTS z wyszczególnieniem okna z przykładowym próbkowaniem asynchronicznym.

Czerwone pionowe linie w oknie czasowym przedstawiają moment pobrania par próbek sygnału. Każda para próbek składa się z dwóch punktów o współrzędnych x_i, y_i , oddalonych od siebie o zadane opóźnienie Δt . Próbkki pobierane są z różnych miejsc przebiegu sygnału, a okres próbkowania T_s nie jest powiązany z przepływnością. Z zebranych par próbek tworzony jest dwuwymiarowy wykres punktowy tzw. portret fazy. Kształt portretu fazy zależny jest od wielu parametrów sygnału. Jeżeli przebieg sygnału w trakcie transmisji jest niezakłócony to kształt portretu przybiera prostą i czytelną postać. Na rys. 3.12 przedstawiono przykładowe portrety fazowe dla sygnałów wolnych od zakłóceń dla modulacji DPSK i OOK oraz opóźnień bitowych: 0,25; 0,5 oraz 1.

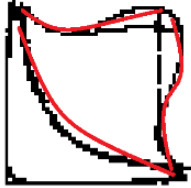
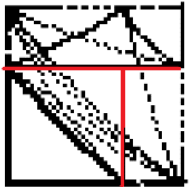
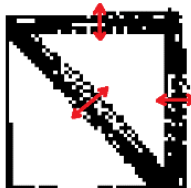


Rys. 3.12 Przykładowe niezakłócone portrety fazy dla wybranych modulacji i opóźnień bitowych.

W przypadku wystąpienia zakłóceń kształt portretu fazy ulega różnym zniekształceniom w zależności od rodzaju i intensywności zjawiska. Duża wrażliwość kształtu na zakłócenia powoduje, że metoda ADTS może być wykorzystywana do równoczesnego monitorowania wielu zjawisk. Jak już wspomniano na początku pracy, do procesu monitorowania wybrano

zjawiska dyspersji chromatycznej, przeniku optycznego oraz szumu ASE. Metoda ADTS umożliwia ich monitorowanie w szerokim zakresie wartości niezależnie od szybkości transmisji i formatu modulacji. Każde zjawisko ma inny wpływ na reprezentację graficzną portretu fazy metody ADTS, a to może się potencjalnie przekładać na lepszą efektywność np. w zastosowaniu splotowych sieci neuronowych do wyznaczania wartości liczbowych tych zjawisk. Wymienione zjawiska można w prosty sposób zamodelować w środowisku symulacyjnym VPIphotonics [41] dzięki czemu możliwe jest wygenerowanie bardzo dużej liczby danych, a te z kolei są niezbędne dla sieci splotowych w procesie uczenia. W tabeli 3.1 przedstawiono charakterystykę wpływu danego zjawiska na kształt portretu fazy dla modulacji OOK i opóźnienia 1 bit. Każde ze zjawisk w przypadku wzrostu intensywności oddziałuje na inny fragment portretu fazy powodując większe zniekształcenie tylko w tym konkretnym obszarze.
















Tabela 3.1 Kształt portretu fazy dla zjawisk dyspersji chromatycznej, przeniku i szumu ASE dla modulacji OOK i opóźnienia 1 bit.

Zjawisko	Portret fazy	Wpływ zjawiska na kształt portretu fazy
dyspersja chromatyczna		Wystąpienie zjawiska dyspersji chromatycznej w transmitowanym sygnale jest odwzorowane na portrecie fazy zafalowaniem przekątnej oraz górnego i prawego boku (kolor czerwony). Przy małej mocy zjawiska obserwuje się wyraźne ugiętą przekątną. Wraz ze wzrostem intensywności zjawiska następuje większe zafalowanie górnego i prawego boku portretu fazy. Przy dużej intensywności zjawiska następuje wyraźne rozwarstwienie kształtu portretu fazy i ograniczenie jego czytelności.
przenik optyczny wewnątrzkanałowy		Występowanie zjawiska przeniku o małej mocy objawia się poprzez rozproszenie sygnału na przekątnej oraz lekkie falowanie na górnym i prawym boku portretu fazy. Wzrost mocy zjawiska przeniku powoduje powstanie dodatkowych przekątnych oraz mniejszych okien, które zostały oznaczone na portrecie fazy czerwonymi odcinkami.
szum ASE (parametr OSNR)		Wystąpienie zakłócenia spowodowanego zjawiskiem szumu ASE objawia się poprzez poszerzenie sygnału (rozmycie próbek) na przekątnej oraz na górnym i prawym boku portretu fazy (czerwone strzałki). Wzrost szumu powoduje spadek wartości OSNR i coraz większe rozproszenie sygnału, aż do uzyskania nieczytelnej rozmytej chmury punktów.

Technika ADTS poza możliwością monitorowania sygnałów o różnych formatach modulacji i przepływnościach pozwala również na jednoczesne monitorowanie wielu zjawisk. Układ pomiarowy w metodzie ADTS wprowadza pewne utrudnienie, ponieważ wymagane jest zastosowanie precyzyjnej linii opóźniającej, z której otrzymywana jest druga wartość próbek

z pary. W tabeli 3.2 przedstawiono przykładowe portrety fazy uzyskane metodą ADTS. Zawierają one równocześnie występujące zjawiska dla modulacji DPSK i OOK oraz czasu trwania bitu 0,25; 0,5 oraz 1.

Tabela 3.2 Przykładowe portrety fazy dla różnych modulacji oraz opóźnień bitowych.

				
DPSK 0,25 bit, CD 694,449 ps/nm, przenik 20,395 dB, OSNR 11,442 dB	DPSK 0,25 bit, CD 1512,739 ps/nm, przenik 28,661 dB, OSNR 25,283 dB	DPSK 0,5 bit, CD 1181,251 ps/nm, przenik 27,328 dB, OSNR 28,136 dB	DPSK 1 bit, CD 912,196 ps/nm, przenik 29,901 dB, OSNR 20,616 dB	DPSK 1 bit, CD 472,84 ps/nm, przenik 11,334 dB, OSNR 13,851 dB
				
DPSK, 1 bit, CD 1562,795 ps/nm, przenik 11,947 dB, OSNR 20,952 dB	OOK, 0,25 bit, CD 1258,652 ps/nm, przenik 13,073 dB, OSNR 23,655 dB	OOK, 0,25 bit, CD 411,68 ps/nm, przenik 27,565 dB, 29,18 dB	OOK, 0,25 bit, CD 832,638 ps/nm, przenik 29,82 dB, OSNR 18,721 dB	OOK, 0,25 bit, CD 1372,233 ps/nm, przenik 28,993 dB, OSNR 19,794 dB
				
OOK, 0,5 bit, CD 411,68 ps/nm, przenik 27,565 dB, OSNR 29,18 dB	OOK 0,5 bit, CD 1056,313 ps/nm, przenik 11,104 dB, OSNR 15,809 dB	OOK, 0,5 bit, CD 1526,577 ps/nm, przenik 17,905 dB, OSNR 12,477 dB	OOK, 1 bit, CD 512,404 ps/nm, przenik 29,403 dB, OSNR 22,228 dB	OOK, 1 bit, CD 1585,608 ps/nm, przenik 11,668 dB, OSNR 11,741 dB

Technika ADTS bardzo dobrze radzi sobie z rozróżnieniem zjawisk poprzez reprezentację graficzną, jednak w celu wyznaczenia wartości liczbowych poszczególnych zakłóceń, niezbędne jest wykorzystanie dodatkowej techniki. Do wyznaczania wartości parametrów opisujących zjawiska degradujące transmisję danych wykorzystuje się [13]: maszynę wektorów nośnych SVM (ang. *Support Vector Machine*), detekcję homodynowa, metrykę Hausdorffa, sztuczne sieci neuronowe, funkcję kernel, transformatę Hougha. Poniżej przedstawiono krótką charakterystykę każdej z metod.

Technika SVM [39], [40], [42] wykorzystuje specjalny algorytm komputerowy do nauki rozpoznawania wartości liczbowych parametrów opisujących zjawiska na podstawie przypisywania etykiet z zadanymi wartościami do obiektów. Jest szeroko stosowana w problemach klasyfikacji oraz w regresji [43]. Zastosowanie techniki SVM w połączeniu

z ADTS zaprezentowane w [39], [40], [42] pozwala na monitorowanie wartości liczbowych OSNR w zakresie 10 – 30 dB, dyspersji chromatycznej w zakresie od -1400 do 1400 ps/nm, dyspersji polaryzacyjnej w zakresie 0 – 60 ps oraz przeniku w zakresie 15 – 25 dB. Metoda została wykorzystana dla transmisji (przepływność, kodowanie, modulacja): 10 Gbit/s NRZ-OOK, 40 Gbit/s NRZ-DPSK, 40 Gbit/s RZ-DQPSK i 80 Gbit/s PM-DQPSK (ang. *Polarization Multiplexed Quadrature Phase Shift Keying*).

W detekcji homodynowej sygnał optyczny jest próbkowany za pomocą odbiornika, który składa się z lasera pełniącego rolę lokalnego oscylatora, ze sprzęgacza hybrydowego realizującego rozgałęzienie 90 stopniowe oraz kontrolera polaryzacji służącego do wyrównania stanu polaryzacji lokalnego oscylatora i sygnału wejściowego. W ten sposób na wyjściu układu można uzyskać parę spróbkowanych danych zawierających informacje o składowej kwadraturowej Q (amplitudzie) i składowej fazowej I (fazie sygnału), w której zwykle zawarte są przesyłane informacje [44]. Przy pomocy tej techniki wraz z ADTS można równocześnie monitorować OSNR, szum fazowy oraz dyspersję chromatyczną, niezależnie od formatu modulacji. Autorzy pracy [44] w celach demonstracyjnych wykorzystali omawianą technikę do monitorowania zjawisk OSNR w zakresie 10 – 30 dB oraz dyspersji chromatycznej w zakresie 0 – 750 ps/nm dla transmisji 10 Gbit/s NRZ-DPSK.


Jedną z metod porównywania kształtów jest miara odległości Hausdorffa. Metoda ta opiera się na pomiarze odległości map krawędziowych i mierzy niedopasowanie między dwoma zestawami punktów [45], [46]. Metryka Hausdorffa zaprezentowana w [47] została użyta do monitorowania zjawiska dyspersji chromatycznej w zakresie 0 – 400 ps/nm dla transmisji 40 Gbit/s NRZ-DQPSK (ang. *Non to Return Zero Differential Quarternary Phase Shift Keying*). W innej dostępnej pracy [19] metrykę Hausdorffa wykorzystano w transmisji dla przepływności 10 Gbit/s kodowaniu NRZ i modulacji OOK. Metoda sprawdza się do oceny wpływu jednego zjawiska, przy małej intensywności występowania pozostałych zjawisk. Dla przykładu w celu wyznaczenia wartości zjawiska dyspersji chromatycznej z błędem maksymalnym 15 ps/nm wymagane jest, aby OSNR był nie mniejszy niż 30 dB, a DGD reprezentujące zjawisko dyspersji polaryzacyjnej nie większe niż 15 ps. Aby wyznaczyć DGD z dokładnością do 1 ps, dyspersja chromatyczna nie może przekraczać 80 ps/nm, a OSNR nie może być mniejszy niż 30 dB. Wyznaczenie wartości OSNR z dokładnością do 0,5 dB jest możliwe, gdy dyspersja chromatyczna jest mniejsza od 160 ps/nm, a DGD mniejsze od 15 ps. Dodatkowo ustalono, że najlepsze rezultaty w wyznaczaniu wartości dyspersji chromatycznej i OSNR uzyskuje się przy opóźnieniu 1 bitu, natomiast dla DGD przy 0,5 bitu [19].

Sztuczne sieci neuronowe to algorytmy obliczeniowe inspirowane biologicznymi sieciami neuronowymi mózgu. Opierają się na zbiorze połączonych jednostek lub węzłów zwanych sztucznymi neuronami, które w przybliżeniu modelują neurony w biologicznym mózgu. Każde połączenie, podobnie jak synapsy w mózgu, może przekazywać sygnał do innych neuronów. Sztuczny neuron, który odbiera sygnał, przetwarza go i może pobudzać podłączone do niego neurony. Sygnał wyjściowy każdego neuronu jest obliczany przez nieliniową funkcję sumy jego sygnałów wejściowych. Połączenia nazywane są krawędziami. Neurony i krawędzie mają zazwyczaj wagę, która dostosowuje się wraz z postępem uczenia. Waga zwiększa lub zmniejsza siłę sygnału przy połączeniu. Neurony mogą mieć próg taki, że sygnał jest wysyłany tylko wtedy, gdy sygnał zagregowany przekroczy ten próg. Zazwyczaj neurony są agregowane w warstwy. Różne warstwy mogą wykonywać różne przekształcenia na swoich danych wejściowych. Sygnały wędrują z pierwszej warstwy (warstwy wejściowej) do ostatniej warstwy (warstwy wyjściowej), po wielokrotnym przejściu przez nie. Nauka sieci polega na dostosowaniu jej wag w celu poprawy dokładności wyniku. Odbywa się to poprzez minimalizację obserwowanych błędów. Nauka jest zakończona, gdy badanie dodatkowych obserwacji nie zmniejsza wskaźnika błędów. Jeśli błąd jest zbyt wysoki należy przebudować sieć [48], [49], [50]. W pracy [51] sieci neuronowe wykorzystano do równoczesnego wyznaczania wartości liczbowych zjawisk szumu ASE poprzez OSNR w zakresie 15 – 30 dB, dyspersji chromatycznej w zakresie 0 – 55 ps/nm oraz dyspersji polaryzacyjnej poprzez DGD w zakresie 0 – 30 ps dla przepływności 10 Gbit/s, kodowania NRZ i modulacji OOK. Uzyskano przy tym następujące dokładności wyznaczania parametrów: dyspersji chromatycznej z błędem ± 30 ps/nm w zakresie 100 – 500 ps/nm, OSNR z błędem ± 2 dB w zakresie 18-30 dB oraz DGD z błędem ± 3 ps w zakresie 5 – 25 ps.

Metoda kernel jest narzędziem służącym do badania ogólnych typów relacji w danych (np. klasyfikacja, regresja itd.) za pomocą algorytmów analizy wzorców liniowych. Algorytmy liniowe są niezwykle wydajne i dobrze rozumiane, zarówno z perspektywy statystycznej jak i obliczeniowej. Metoda kernel składa się z dwóch części: obliczeń macierzy kernela odpowiadających za mapowanie w przestrzeni cech oraz algorytmu uczenia opartego na macierzy kernela, który jest zaprojektowany do wykrywania liniowych wzorców w przestrzeni cech. Metoda kernel jest reprezentowana przez funkcję, która dla danych dwóch wzorców f i f^* zwraca liczbę rzeczywistą charakteryzującą ich podobieństwo. Prostym rodzajem miary podobieństwa pomiędzy dwoma wektorami jest iloczyn skalarny [52], [53]. Jeśli znane są wszystkie pary iloczynów wewnętrznych pomiędzy wektorami obrazu dla wszystkich par punktów danych, można wykonać większość metod wykrywania wzorców liniowych znanych

ze statystyk wielowymiarowych i uczenie maszynowe bez konieczności podawania współrzędnych takich punktów [53]. W pracy [40] metodę Kernela wykorzystano do wyznaczania wartości monitorowanych parametrów dla transmisji o przepływności 40 Gbit/s, kodowaniu NRZ i formacie modulacji DPSK. Przy zmieniającym się parametrze OSNR w zakresie od 15 do 25 dB uzyskano dokładność wyznaczania dyspersji chromatycznej z błędem ± 11 ps/nm w zakresie 0 – 400 ps/nm oraz $\pm 1,9$ ps dla DGD w zakresie 0 – 22,5 ps.

Transformata Hougha wykorzystywana jest do analizy wykresów i wyznaczania informacji ilościowych [54], [55], np. do określenia parametrów geometrycznych obiektów (linie, okręgi). Zasadę przekształcenia przedstawiono na rys. 3.13. Jako przykład, analizę prostej S ilustruje rys. 3.13 a). Zakłada się, że początek układu współrzędnych znajduje się w środku. Prosta S na wykresie zbudowana jest z pojedynczych punktów. Jednym z nich jest punkt $P1$. Przez każdy punkt może być poprowadzona nieskończona liczba linii prostych S opisanych we współrzędnych biegunowych jako leżących w odległości R i pod kątem ϕ od początku układu współrzędnych. Na przykład, w trakcie obracania linii S wokół punktu $P1$ zostanie wykreślona sinusoidalna krzywa $K1$ (rys. 3.13 b). Krzywa ta jest odzwierciedleniem wszystkich linii przechodzących przez punkt $P1$ w trakcie obracania.



Rys. 3.13 Zasada przekształcenia Hougha.

Na rys. 3.13 b) krzywe przecinają się w punkcie A. Wspólny punkt przecięcia krzywych wskazuje parametry prostej aproksymującej punkty w przestrzeni. Współrzędne R i ϕ punktu A opisują położenie analizowanego kształtu prostej na wykresie (rys. 3.13 b). Ponieważ umiejscowienie funkcji z opóźnieniem zależy od kształtu przebiegu, zmiany w przebiegu można opisać numerycznie jako współrzędne R lub ϕ [56], [57]. Zastosowanie transformaty Hougha zademonstrowano w badaniach [24], [54], [58] do monitorowania OSNR w zakresie 8,7 – 35 dB i dyspersji chromatycznej w zakresie od -600 do 600 ps/nm dla transmisji: 10 Gbit/s RZ-DPSK, 20 Gbit/s RZ-DQPSK oraz 40 Gbit/s NRZ-DQPSK. W innych dostępnych badaniach transformatę Hougha zastosowano w transmisji dla sygnału o przepływności 10 Gbit/s, kodowaniu NRZ i modulacji DQPSK uzyskując dokładność wyznaczania wartości

dyspersji chromatycznej z błędem ± 25 ps/nm w zakresie 0 – 600 ps/nm oraz OSNR z błędem ± 3 dB w zakresie 15 – 30 dB.

W tabeli 3.3 przedstawiono podsumowanie omawianych metod do wyznaczania wartości liczbowych z danych uzyskanych metodą ADTS. We wszystkich pracach autorzy przedstawili informację o zakresach monitorowanych zjawisk. W części prac zostały jednak pominięte informacje o błędach wyznaczanych wartości parametrów opisujących zakłócenia. Dla tych pozycji w polu „Błąd” pozostawiono puste miejsce.

Tabela 3.3 Porównanie technik do wyznaczania wartości liczbowych z metody ADTS.

Technika	Format	Zjawiska	Błąd
maszyna wektorów nośnych [39], [40], [42]	10 Gbit/s NRZ-OOK, 40 Gbit/s NRZ-DPSK, 40 Gbit/s RZ-DQPSK, 80 Gbit/s PM-DQPSK	OSNR 10 do 30 dB, CD –1400 do 1400 ps/nm, PMD 0 do 60 ps, Przenik 15 do 25 dB	-
detekcja homodynowa [44]	10 Gbit/s NRZ-DPSK	OSNR 10 do 30 dB, CD 0 do 750 ps/nm	-
metryka Hausdorffa [19], [47]	10 Gbit/s NRZ OOK	CD 0 do 160 ps/nm, OSNR > 30 dB, PMD < 15 ps	CD < 15 ps/nm, gdy OSNR > 30 dB i DGD < 15 ps, OSNR < 0,5 dB, gdy CD < 160 ps/nm, a DGD < 15 ps
	40 Gbit/s NRZ-DQPSK	0 – 400 ps/nm	-
sztuczne sieci neuronowe [51]	10 Gbit/s NRZ OOK	OSNR 15 do 30 dB, CD 0 do 55 ps/nm, PMD 0 do 30 ps	CD ± 30 ps/nm, gdy CD od 100 do 500 ps/nm, OSNR ± 2 dB, gdy OSNR od 18 do 30 dB DGD ± 3 ps, gdy DGD od 5 do 25 ps
metoda Kernel [40]	40 Gbit/s NRZ DPSK	CD 0 do 400 ps/nm, OSNR 15 do 25 dB, PMD 0 do 22,5 ps	CD ± 11 ps/nm, gdy CD od 0 do 400 ps/nm, a OSNR od 15 do 25 dB, DGD $\pm 1,9$ ps, gdy DGD od 0 do 22,5 ps
transformata Hougha [24], [54], [58]	10 Gbit/s NRZ DQPSK	CD 0 do 600 ps/nm, OSNR 15 do 30 dB	CD ± 25 ps/nm OSNR ± 3 dB
	10 Gbit/s RZ-DPSK, 20 Gbit/s RZ-DQPSK 40 Gbit/s NRZ-DQPSK	OSNR 8,7 do 35 dB, CD -600 do 600 ps/nm	-

Wykorzystywane do tej pory techniki wyznaczania wartości liczbowych nie spełniają kryteriów wymaganych od nowoczesnych systemów monitorowania. Każda z nich charakteryzuje się pewnymi ograniczeniami w dokładności wyznaczania wartości, zakresie detekcji oraz formatach modulacji (brak jest informacji o ograniczeniach w doborze formatów modulacji). Autorzy części prac nie podają dodatkowo błędów wyznaczanych wartości. W przypadku części

metod, dokładność wyznaczania wartości poszczególnych zjawisk, jest zależna od poziomu intensywności zjawisk współwystępujących. Oznacza to, że zjawiska mogą się nakładać na siebie co może uniemożliwić wyznaczenia ich wartości z odpowiednią dokładnością. Zasadne jest zatem poszukiwanie nowego narzędzia, które w jednoznaczny sposób będzie automatycznie wyznaczać wartości parametrów kilku równocześnie występujących zjawisk niezależnie od przepływności, typu modulacji oraz intensywności tych zjawisk i ich wzajemnego oddziaływania między sobą.

Zaprezentowane techniki monitorowania mają swoje wady i zalety. Wykres oka jest podstawową techniką dostarczającą informacje o jakości sygnału i jest bardzo wrażliwy na wszystkie zjawiska, które ograniczają tę jakość i wpływają na kształt wykresu. Z tego powodu trudno jest wskazać źródło pochodzenia danego zakłócenia. Przy pomocy tej metody można monitorować parametry rozwartości, wysokości i szerokości oka, jitter oraz parametr Q dla różnych przepływności. Metody oparte o pomiar tonu umożliwiają monitorowanie parametrów dyspersji chromatycznej i polaryzacyjnej, optycznego stosunku sygnału do szumu oraz mocy sygnału w kanale dla przepływności do 10 Gbit/s. Wymagają jednak modyfikacji w konstrukcji nadajnika, aby móc dodać do pasma dodatkowy sygnał (ton) powodując wzrost złożoności systemu. Niemożliwy jest też równoczesny pomiar obu dyspersji, a dla miarodajnych pomiarów konieczne jest wyizolowanie wpływu jednej z nich. W przypadku dyspersji chromatycznej zakres pomiarowy zwiększa się wraz ze wzrostem częstotliwości tonu. Pomiar dyspersji polaryzacyjnej możliwy jest niezależnie od tonu, jednak sam zakres monitorowania jest mocno ograniczony do 15 ps DGD. Techniki wykorzystujące asynchroniczny histogram amplitudy pozwalają na monitorowanie dyspersji chromatycznej i polaryzacyjnej oraz szumu ASE, dla różnych formatów modulacji (DPSK, OOK, RZ-DPSK, NRZ-DPSK, CSRZ-DPSK, RZ-DQPSK) oraz przepływności do 20 Gbit/s, przy stosunkowo małej złożoności układu monitorowania. Metoda nie pozwala jednak na monitorowanie zakłóceń w dużych zakresach pomiarowych (-600 do 500 ps/nm dla dyspersji chromatycznej i od 16 do 40 dB dla szumu ASE), które dodatkowo wyraźnie zwiężają się wraz ze wzrostem przepływności, co jest wadą tej metody. Możliwości monitorowania zależne są również od przyjętego formatu modulacji. Metoda PAED pozwala na monitorowanie zjawiska dyspersji chromatycznej i polaryzacyjnej oraz szumu ASE dla formatów modulacji RZ-OOK i NRZ-OOK. Posiada jednak ograniczenia w zakresie monitorowania poszczególnych parametrów. Zakres ten wyraźnie zmniejsza się wraz ze wzrostem przepływności, która ograniczona jest do 20 Gbit/s co stanowi wadę tej metody. Ciekawą alternatywę dla wymienionych metod stanowi technika wykorzystująca rekonstrukcję wykresu oczkowego, pozwalająca monitorować dyspersję chromatyczną, DGD

oraz OSNR dla przepływności do 40 Gbit/s. Metodę zademonstrowano dla modulacji RZ-OOK (brak jest informacji o innych typach modulacji). Niestety monitorowanie poszczególnych parametrów możliwe jest tylko dla małych zakresów pomiarowych (od 0 do 32 ps/nm dla dyspersji chromatycznej, od 0 do 8 ps dla DGD, od 20 do 40 dB dla OSNR).

Bardzo popularną i często wykorzystywaną w różnych odmianach techniką jest ADTS. Spośród wszystkich przedstawionych metod charakteryzuje się ona najlepszymi właściwościami w zakresie monitorowania. Umożliwia bardzo dobrą graficzną reprezentację zjawisk dyspersji chromatycznej i polaryzacyjnej, szumu ASE oraz przeniku optycznego w bardzo szerokim zakresie pomiarowym, niezależnie od formatu modulacji i przepływności. Ponadto jest szybka i nie wymaga skomplikowanego aparatu pomiarowego oraz odzyskiwania synchronizacji zegara. Z tego względu zdecydowano, że metoda ta jest najlepsza spośród wszystkich sklasyfikowanych technik monitorowania parametrów optycznych oraz będzie tematem dalszych prac prowadzonych w ramach rozprawy doktorskiej. Technika ADTS do wyznaczenia wartości liczbowych parametrów opisujących zjawiska wymaga zastosowania dodatkowych algorytmów (podrozdział 3.2.6). Nie umożliwiają one jednak wyznaczenia wartości parametrów na odpowiednio dobrym poziomie (zgodnie z tabelą 2.1), dlatego zdecydowano się w dalszej części pracy wykorzystać splotowe sieci neuronowe, których najczęstszym zastosowaniem są zagadnienia związane z przetwarzaniem obrazów. Charakterystykę sieci splotowych przedstawiono w rozdziale nr 4.

4. Splotowe sieci neuronowe

Splotowe sieci neuronowe *CNN*, *ConvNet* (ang. *Convolutional Neural Network*) są to wielowarstwowe sieci neuronowe wykorzystywane w metodzie głębokiego uczenia, która jest jedną z podstawowych technik uczenia maszynowego. Głównym elementem wyróżniającym tego typu sieci są warstwy splotowe (ang. *convolution layers*), które umożliwiają hierarchiczną ekstrakcję cech. Oznacza to, że w początkowych warstwach sieć uczy się rozpoznawać podstawowe kształty np. krawędzie, kreski, kropki, kolory, gradienty, a w następnych bardziej złożone kształty np. nos, oko, usta, natomiast w ostatnich warstwach całe obiekty np. twarz, samochód. Im więcej warstw ukrytych zostanie zastosowanych, tym bardziej skomplikowane cechy zostaną wyekstrahowane. Warstwy splotowe cechują się dodatkowo wysoką odpornością na przeuczenie, tzn. stan, w którym w trakcie uczenia sieci następuje jej nadmierne dopasowanie do drugorzędnych i nieistotnych szczegółów, nie mających istotnego znaczenia z punktu widzenia ważnych cech rozwiązywanego problemu. Sieci splotowe (sieci ze splotem lub potocznie sieci konwolucyjne) stanowią przykład głębokich sieci neuronowych. Za najważniejszą pracę naukową, która określiła podstawową architekturę oraz algorytm uczący CNN uważa się publikację Yanna LeCuna z 1998 roku [59]. Należy również wspomnieć o pracy z 1980 roku [60], w której Kunihiko Fukushima inspirowany się na badaniach prowadzonych w latach 60 XX wieku na korze mózgowej kota [61] opracował model sieci neocognitron wykorzystywany do odręcznego rozpoznawania znaków. W odróżnieniu od podejścia Fukushimy, LeCun zastosował w swoim algorytmie metodę wstecznej propagacji błędów, która w znaczny sposób zwiększyła wydajność procesu uczenia sieci oraz dokładność gotowych modeli opisujących nauczone sieci. Koncepcja LeCuna zbiegła się w czasie z rozwojem technologii informatycznych umożliwiając znaczne przyspieszenie obliczeń co również korzystnie wpłynęło na dalszy rozwój CNN i powstanie ich nowych modyfikacji np. sieci rekurencyjnych LSTM (ang. *Long Short-Term Memory*), ograniczonej wielowarstwowej maszyny Boltzmanna RBM (ang. *Restricted Boltzmann Machine*) czy np. autoenkoderów.

Sieci splotowe są obecnie szeroko wykorzystywane w wielu dziedzinach takich jak: rozpoznawanie i detekcja obrazów (twarzy, samochodów, znaków drogowych i innych), zamiana dźwięku na tekst i odwrotnie (tłumacze), filtry cyfrowe, pojazdy autonomiczne (sterowanie samochodami, robotami, statkami powietrznymi), diagnostyka medyczna (klasyfikacja i rozpoznawanie schorzeń), przetwarzanie wideo (poprawianie jakości,

kolorowanie obrazu), analiza obrazów (poprawa jakości, uwydatnianie lub wyodrębnianie cech, rekonstrukcja) i wielu innych.

W podrozdziale 4.1 przedstawiono podstawowe informacje o matematycznej operacji splotu oraz jej zastosowaniach w inżynierii obrazów. Podrozdział 4.2 zawiera informacje o sieciach neuronowych ze splotem, które zaproponował Yann LeCun [59].

4.1 Splot

Zgodnie z definicją [62] splot to zarówno działanie na dwóch funkcjach ciągłych, które zapisuje się znakiem „*”, a także wynik tego działania. Definicję splotu dwóch funkcji ciągłych przedstawiono na poniższym wzorze [63]–[65]:

$$(f * g)(x) = \int_{-\infty}^{\infty} f(y)g(x - y) dy \quad (4.1)$$

gdzie: $f: \mathbb{R} \rightarrow \mathbb{R}$ i $g: \mathbb{R} \rightarrow \mathbb{R}$

Splot w przypadku funkcji dyskretnych znalazł szerokie zastosowanie np. w przetwarzaniu sygnałów czy rozpoznawaniu obrazów i ma następującą postać [63]–[65]:

$$(f * g)(n) = \sum_{m=-\infty}^{\infty} f(m)g(n - m) \quad (4.2)$$

gdzie: $f: \mathbb{Z} \rightarrow \mathbb{Z}$ i $g: \mathbb{Z} \rightarrow \mathbb{Z}$

Dla funkcji dyskretnych dwuwymiarowych splot znalazł zastosowanie w przetwarzaniu obrazów i wyrażony jest następująco [63]–[65]:

$$(f * g)(m, n) = \sum_{s=-\infty}^{\infty} \sum_{t=-\infty}^{\infty} f(s, t)g(m - s, n - t) \quad (4.3)$$

gdzie: $f: \mathbb{Z} \times \mathbb{Z} \rightarrow \mathbb{Z}$ i $g: \mathbb{Z} \times \mathbb{Z} \rightarrow \mathbb{Z}$.

Ostatni wariant ma szerokie zastosowanie w zagadnieniach związanych z analizą obrazów. Czarno biały obraz zapisany w postaci cyfrowej o wymiarach X i Y można przedstawić w postaci funkcji $f: \{0, 1, \dots, X - 1\} \times \{0, 1, \dots, Y - 1\} \rightarrow \{0, 1, \dots, 255\}$, gdzie dziedzina funkcji f to współrzędne piksela, a jej przeciwdziedzina to jasność/ciemność pikseli. Skala szarości jest liczbą całkowitą z zakresu $0 - 255$. Za przykład posłużyła tutaj standardowa 8 bitowa skala

szarości, ponieważ często jest wykorzystywana do zapisu obrazów monochromatycznych. Taką funkcję można zdefiniować na całym \mathbb{Z} przy założeniu, że $f(x, y) = 0$, gdy jedna ze współrzędnych x, y wykracza poza granicę obrazu tzn. jest mniejsza od 0 lub $x > X - 1$ albo $y > Y - 1$. Reprezentację splotu dla obrazu czarno białego przedstawiono za pomocą następującego wzoru (który jest zmodyfikowaną wersją wzoru 4.3) [63]–[65]:

$$(f * g)(m, n) = \sum_{s=0}^{H-1} \sum_{t=0}^{W-1} f(s, t)g(m + s, n + t) \quad (4.4)$$

gdzie: H, W - wysokość i szerokość jądra splotu.

Powyższe reprezentacje dotyczą operacji splotu dla funkcji ciągłej i dyskretnej. Z większą liczbą zastosowań można zapoznać się w [65]. Ze względu na tematykę poruszaną w ramach niniejszej rozprawy doktorskiej, zaprezentowano poniżej przykład operacji splotu dla filtrowania liniowego. Jest to jedna z najpotężniejszych metod poprawiania jakości obrazu, w której część widma częstotliwości sygnału jest modyfikowana przez funkcję przenoszenia filtra. Obrazy wyjściowe charakteryzują się sumą splotów między obrazem wejściowym, a odpowiedzią impulsową filtra. Filtrowanie liniowe obrazu wyrażone zostało wzorem [65]:

$$h(m, n) = \sum_{s=0}^M \sum_{t=0}^N g(m - s, n - t)f(s, t) = g(m, n) ** f(m, n) \quad (4.5)$$

gdzie: M i N – wymiary obrazu w pikselach, $h(m, n)$ – obraz wyjściowy, $g(m, n)$ – funkcja przenoszenia filtra, $f(m, n)$ – obraz wejściowy, $**$ - splot dwuwymiarowy.

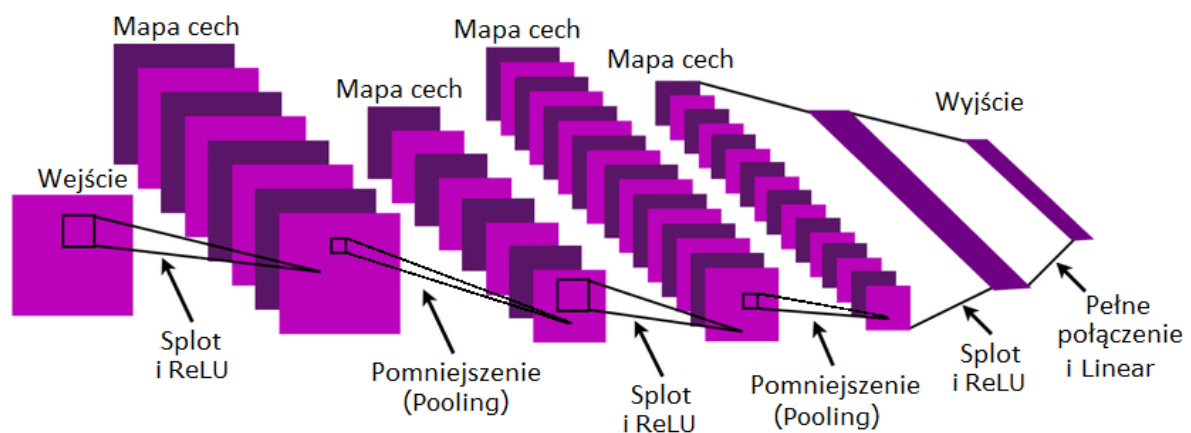
4.2 Sieci neuronowe ze splotem

Typowa sieć splotowa wykorzystywana w dziedzinie rozpoznawania obrazów zbudowana jest z warstwy wejściowej, warstw splotowych, warstw pomniejszających, warstw w pełni połączonych, które stanowią klasyczną sieć neuronową oraz warstwy wyjściowej. W sieciach splotowych występują zatem trzy typy warstw ukrytych, mianowicie:

- warstwy splotowe, w których na wartości splotu wykonywana jest wybrana funkcja aktywacji,
- warstwy pomniejszające zamiennie określane warstwami łączącymi lub próbkującymi, w których macierz pikseli większych rozmiarów przeliczana jest na macierz pikseli mniejszych rozmiarów,

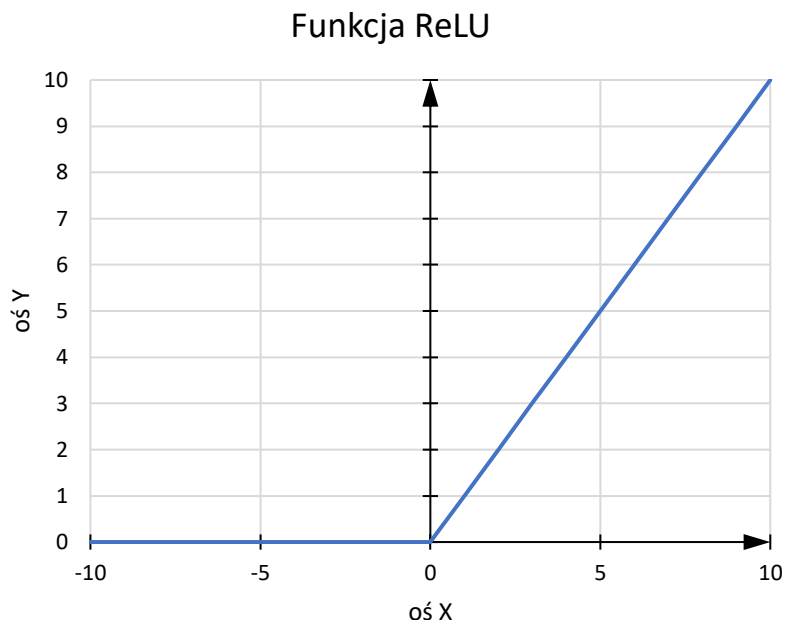
- warstwy w pełni połączone, w których na sumie ważonej pobudzeń wykonywana jest sigmoidalna funkcja aktywacji, najczęściej jest to inna funkcja aktywacji niż wykorzystywana w warstwach splotowych.

Na rys. 4.1 przedstawiono standardową i uogólnioną architekturę sieci splotowej Le-Net5 z trzema warstwami ukrytymi [66]. W warstwach splotowych na wartościach splotu wykonywana jest funkcja ReLU (funkcja została opisana w dalszej części pracy) natomiast w warstwach w pełni połączonych na sumie ważonej pobudzeń wykonywana jest funkcja tangens hiperboliczny (tanh).



Rys. 4.1 Standardowa architektura sieci splotowej Le-Net5 wprowadzona przez Yanna LeCuna.


Warstwę wejściową stanowi dwuwymiarowa macierz znormalizowanych wartości, o wymiarze zależnym od szerokości i wysokości obrazu. W przypadku obrazów kolorowych RGB, macierz wejściowa zbudowana jest z trzech warstw, które odpowiadają poszczególnym kanałom obrazu. Najważniejszymi elementami sieci splotowej są trzy typy warstw ukrytych: warstwy splotowe, warstwy próbkujące oraz warstwy w pełni połączone. W **warstwach splotowych** wykonywana jest operacja splotu, w wyniku której w trakcie filtracji obrazu wyodrębniane są jego najważniejsze cechy. Następnie na wartości operacji splotu wykonywana jest funkcja aktywacji. Funkcja aktywacji wprowadza wyższy stopień złożoności i wspomaga sieć w nauce skomplikowanych wzorców. Jedną z najpopularniejszych funkcji aktywacji jest ReLU (ang. *Rectifier Linear Unit*), zwana potocznie od swojego kształtu funkcją rampy (rys. 4.2).




Rys. 4.2 Wykres funkcji aktywacji ReLU. Funkcję ReLU można przedstawić następująco
 $f(x) = \{0 \text{ dla } x < 0; x \text{ dla } x \geq 0\}$.

Funkcja ReLU dzięki swoim właściwościom (łatwa do obliczenia, nie nasycy się i likwiduje problem zanikającego gradientu) w znaczący sposób przyspiesza obliczenia oraz proces uczenia sieci. Z każdą warstwą splotową związana jest **warstwa próbkująca** (ang. *Pooling*). Służy ona do zmniejszenia wymiarów mapy cech wyznaczonej w warstwie poprzedzającej przy równoczesnym zachowaniu najważniejszych informacji o danych cechach. W efekcie zmniejszenia rozmiaru macierzy następuje ograniczenie liczby parametrów oraz spadek wymaganej mocy obliczeniowej. Wpływa to również na zmniejszenie ryzyka przeuczenia sieci. Operacja łączenia w warstwie próbkującej odbywa się w sposób zbliżony do operacji splotu. Mapa cech jest wymnażana przez filtr o zadanym wymiarze (zazwyczaj 2x2) oraz o zdefiniowanym kroku. W operacji próbkowania wykorzystuje się najczęściej dwa podejścia obliczeniowe: z wartości objętych filtrem obliczana jest średnia (ang. *Average Pooling*) lub wybierana jest wartość największa (ang. *Max Pooling*). Przykładowe działanie wspomnianych filtrów przedstawiono na rys. 4.3 a) i b).

a)



b)



Rys. 4.3 Prezentacja działania filtru (2x2) na przykładzie dwóch podejść obliczeniowych, a) operacja Max Pooling, b) Average Pooling.


W sieci CNN występuje z reguły kilka warstw splotowych, a dane z ostatniej z nich zostają spłaszczone do jednego wymiaru i trafiają na wejście do klasycznej sieci neuronowej, w której algorytm uczy się nieliniowych zależności występujących pomiędzy cechami wyznaczonymi w warstwach splotowych. Ten fragment sieci nazywany jest w terminologii CNN **warstwami w pełni połączonymi**, w których w każdym neuronie na sumie ważonej pobudzeń wykonywana jest funkcja aktywacji tangens hiperboliczny (tanh). Następnie pobudzenia przekazywane są do **warstwy wyjściowej**, która jest zwykłym perceptronem dokonującym regresji liniowej lub spłaszczonym zbiorem perceptronów (gdzie w neuronach na sumie ważonej pobudzeń wykonywana jest liniowa funkcja aktywacji). Ukryte warstwy w pełni połączone wraz z warstwą wyjściową stanowią właściwy klasyfikator lub układ regresyjny. Układ ten decyduje o prawdopodobieństwie przynależności obrazu do odpowiedniej klasy bądź kategorii. W trakcie treningu sieci, otrzymane wartości są porównywane z wartościami referencyjnymi, a poprzez algorytm wstecznej propagacji błędów sieć modyfikuje swoje wagi w celu zminimalizowania występującego błędów różnicy pomiędzy tymi wartościami. Proces uczenia jest powtarzany do momentu uzyskania satysfakcjonujących wyników bądź osiągnięcia zadanych ustawień. W podrozdziale 4.2.1 przedstawiono rozszerzenie informacji o sieciach splotowych na przykładzie sieci LeNet-5 stworzonej przez Yana LeCuna.

4.2.1 Sieć LeNet-5

Aby zapewnić pewien stopień niezmienności przesunięcia, skali i zniekształcenia, sieci spłotowe łączą w sobie trzy koncepcje architektury:

- lokalne pola receptywne;
- wspólne wagi;
- próbkowanie przestrzenne lub czasowe.

Na rys. 4.4 przedstawiono standardową architekturę sieci spłotowej LeNet-5 do rozpoznawania znaków zaproponowanej przez Yana LeCuna. Główne warstwy oznaczono według następującej notacji: C_i – warstwy spłotowe (ang. *convolution layers*), S_i – warstwy próbkujące (lub podpróbkujące, ang. *subsampling*), F_i – warstwy w pełni połączone, natomiast i jest indeksem warstwy.



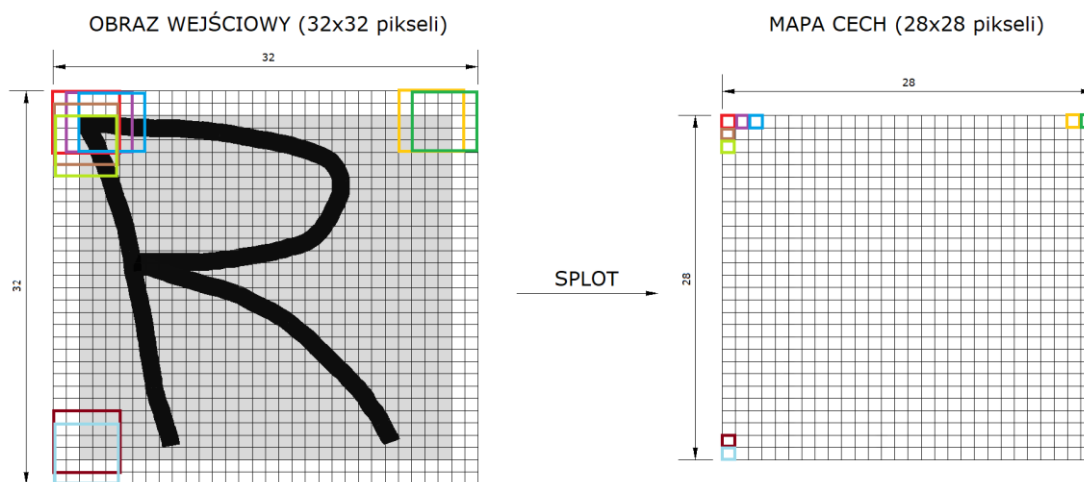
Rys. 4.4 Architektura sieci spłotowej LeNet-5 [59].

Płaszczyzna wejściowa otrzymuje obrazy znaków (np. liter, liczb), które są wyśrodkowane oraz znormalizowane pod względem wielkości. Każda jednostka z macierzy w warstwach C_1 , S_2 , C_3 i S_4 otrzymuje dane wejściowe składające się z małej liczby jednostek znajdujących się w bliskim sąsiedztwie w poprzedniej warstwie. Idea łączenia jednostek z lokalnymi polami receptywnymi na wejściu, sięga idei perceptronu z początku lat 60 i była niemal równoczesna z odkryciem przez Hubela i Wiesela lokalnie wrażliwych, selektywnych pod względem orientacji neuronów w układzie wzrokowym kota [61]. Lokalne połączenia były wielokrotnie wykorzystywane w modelach neuronowych do uczenia wzrokowego [67]–[72]. Dzięki lokalnym polom receptywnym neurony mogą wyodrębnić elementarne cechy wizualne, takie jak zorientowane krawędzie, punkty końcowe, narożniki (lub podobne cechy w innych sygnałach, np. spektrogramach mowy). Cechy te są następnie łączone przez kolejne warstwy w celu wykrycia cech wyższego rzędu. Jak wspomniano wcześniej, zniekształcenia lub przesunięcia danych wejściowych mogą powodować zmianę położenia istotnych cech w macierzy pikseli. Ponadto, elementarne detektory cech, które są użyteczne w jednej części

obrazu, prawdopodobnie będą użyteczne w całym obrazie. Wiedza ta może być wykorzystana poprzez wymuszenie na zestawie jednostek, których pola receptywne znajdują się w różnych miejscach obrazu, identycznych wektorów wag [70], [72], [73].

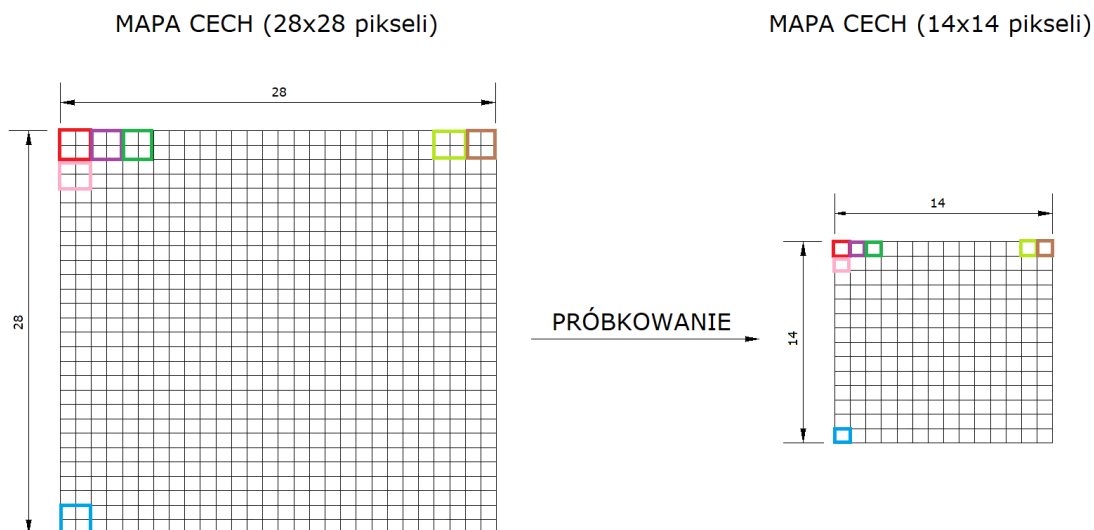
Jednostki w warstwach ($C1$, $S2$, $C3$ i $S4$) są zorganizowane w płaszczyzny (macierze), w obrębie których wszystkie jednostki mają ten sam zestaw wag. Zbiór wyjść jednostek w takiej płaszczyźnie nazywany jest mapą cech. Jednostki w mapie cech są ograniczone do wykonywania tej samej operacji na różnych częściach obrazu. Kompletna warstwa spłotowa ($C1$, $C3$) składa się z kilku map cech (z różnymi wektorami wag), dzięki czemu w każdym miejscu można wyodrębnić wiele cech. Konkretnym tego przykładem jest pierwsza warstwa LeNet-5 (na rys 4.4 warstwa $C1$). Jednostki w tej warstwie ukrytej są zorganizowane w sześć płaszczyzn, z których każda jest mapą cech (rys. 4.5). Jednostka w mapie cech ma 25 wejść połączonych z obszarem 5×5 na wejściu zwanym polem receptywnym jednostki. Każda jednostka ma 25 wejść co oznacza 25 trenowalnych wag oraz trenowalny bias. Bias jest to dodatkowe wejście, na którym występuje stała wartość, natomiast waga dla tego wejścia jest modyfikowana w trakcie procesu uczenia. Pola receptywne sąsiadujących ze sobą jednostek w mapie cech są wyśrodkowane na odpowiadających im sąsiadujących ze sobą jednostkach w poprzedniej warstwie. Z tego względu pola receptywne sąsiadnych jednostek nakładają się na siebie. Na przykład w pierwszej warstwie ukrytej LeNet-5 ($C1$), pola receptywne jednostek sąsiadujących ze sobą w poziomie zachodzą na siebie w czterech kolumnach i pięciu rzędach. Jak wspomniano wcześniej, wszystkie jednostki w mapie cech mają ten sam zestaw 25 wag i ten sam bias, więc wykrywają tę samą cechę we wszystkich możliwych miejscach na wejściu. Pozostałe mapy cech w warstwie używają różnych zestawów wag i biasów, przez co wyodrębniają różne typy cech lokalnych.

W przypadku sieci LeNet-5, w każdej lokalizacji wejściowej sześć różnych typów cech jest ekstrahowanych przez sześć jednostek w takich samych lokalizacjach w sześciu mapach cech. Sekwencyjna implementacja mapy cech skanuje obraz wejściowy za pomocą pojedynczej jednostki, która posiada lokalne pole receptywne i przechowuje stany tej jednostki w odpowiednich miejscach mapy cech (rys. 4.5).



Rys. 4.5 Operacja splotu na obrazie wejściowym o rozmiarze 32x32 pikseli w wyniku której powstaje mapa cech (warstwa C1) o rozmiarze 28x28 pikseli. Splot został przeprowadzony z wykorzystaniem pola receptywnego o rozmiarze 5x5 pikseli. W trakcie tej operacji wykonywanych jest 784 przejść (po 28 dla każdej kolumny i wiersza) z równym krokiem 1. Kolorami zaznaczono przykładowe przejście pola receptywnego przez obraz wejściowy i odpowiadające im obliczone wartości dla mapy cech. Analogiczna procedura wykonywana jest na macierzy S2 i w rezultacie daje macierz C3.

Operacja ta jest równoważna splotowi, po którym następuje addytywna funkcja bias oraz funkcja sigmoidalna (ang. *sigmoid*, *squashing*), stąd nazwa sieć splotowa. Jądro splotu jest zbiorem wag połączeń używanych przez jednostki w mapie cech. Bardzo ważną własnością warstw splotowych jest to, że jeśli obraz wejściowy zostanie przesunięty, to wyjście mapy cech zostanie przesunięte o tę samą wartość, natomiast w przeciwnym wypadku pozostanie niezmiennione. Ta właściwość jest podstawą odporności sieci splotowych na przesunięcia i zniekształcenia obrazu wejściowego. Po wykryciu cechy, jej dokładna lokalizacja staje się mniej istotna. Ważna jest jedynie informacja o jej przybliżonym położeniu względem innych cech. Dla przykładu, jeśli wiadomo, że obraz wejściowy zawiera punkt końcowy w przybliżeniu poziomego odcinka w lewym górnym obszarze, narożnik w prawym górnym obszarze oraz punkt końcowy w przybliżeniu pionowego odcinka w dolnej części obrazu, to można stwierdzić, że obraz wejściowy jest siódmką. Dokładna pozycja każdej z tych cech jest nie tylko nieistotna dla identyfikacji wzorca, ale również potencjalnie szkodliwa, ponieważ pozycje te mogą się różnić dla różnych przypadków danej postaci. Aby temu zapobiec należy zmniejszyć precyzję, z jaką położenie charakterystycznych cech jest kodowane w mapie cech. Można tego dokonać poprzez zmniejszenie rozdzielczości przestrzennej mapy cech. Służy do tego tzw. warstwa próbkująca (lub podpróbkująca, ang. *subsampling*), która dokonuje lokalnego uśredniania i próbkowania, zmniejszając w ten sposób rozdzielczość mapy cech i zmniejszając wrażliwość danych wyjściowych na przesunięcia i zniekształcenia (rys. 4.6).



Rys. 4.6 Przykład operacji próbkowania zmniejszającej rozmiar mapy cech, warstwy $C1$ z 28×28 pikseli do 14×14 pikseli (warstwa $S2$), z wykorzystaniem pola receptywnego o rozmiarze 2×2 . Analogiczna procedura wykonywana jest na macierzy $C3$ i w rezultacie daje macierz $S4$.

Warstwa próbkująca jest drugą warstwą ukrytą w sieci LeNet-5. Warstwa ta składa się z sześciu map cech, po jednej dla każdej mapy w poprzedniej warstwie. Pole receptywne każdej jednostki jest obszarem 2×2 na odpowiadającej jej mapie cech w poprzedniej warstwie. Każda jednostka oblicza średnią ze swoich czterech wejść, mnoży ją przez trenowalny współczynnik, dodaje trenowalny błąd i przekazuje wynik do funkcji sigmoidalnej. Przylegające do siebie jednostki mają nienakładające się przylegające do siebie pola receptywne. W konsekwencji mapa cech warstwy próbkującej ma połowę liczby wierszy i kolumn, względem mapy cech z poprzedniej warstwy. Współczynnik trenowania i bias kontrolują efekt nieliniowości sigmoidalnej. Jeśli współczynnik jest mały, to jednostka działa w trybie quasi-liniowym, a warstwa próbkująca jedynie rozmywa dane wejściowe. Jeśli współczynnik jest duży, jednostki próbkujące mogą być postrzegane jako wykonujące funkcję NOR (negacja sumy logicznej) lub NAND (negacja koniunkcji) w zależności od wartości biasu. Kolejne warstwy spłotowe i próbkowania są zazwyczaj naprzemienne: w każdej warstwie liczba map cech jest zwiększana wraz ze zmniejszaniem rozdzielczości przestrzennej. Każda jednostka w trzeciej warstwie ukrytej może mieć połączenia wejściowe z kilku map cech z warstwy poprzedzającej. Kombinacja spłotki i próbkowania, zainspirowana pojęciami "prostych" i "złożonych" komórek Hubela i Wiesela, została zaimplementowana w Neocognitronie Fukushima [60]. Nie była jednak wtedy dostępna żadna globalnie nadzorowana procedura uczenia, taka jak wsteczna propagacja. Dzięki stopniowej redukcji rozdzielczości przestrzennej kompensowanej stopniowym wzrostem liczby map cech, można osiągnąć duży stopień niezmienności przekształceń geometrycznych

danych wejściowych. Ponieważ wszystkie wagi uczone są za pomocą propagacji wstecznej, sieci spłotowe mogą być postrzegane jako syntetyzujące swój własny ekstraktor cech.

Sieci spłotowe o stałej wielkości znalazły zastosowanie w wielu aplikacjach, między innymi w rozpoznawaniu pisma ręcznego [74], [75], rozpoznawaniu znaków drukowanych maszynowo [76], rozpoznawaniu pisma ręcznego online [77], czy rozpoznawaniu twarzy [78]. Sieci spłotowe o stałym rozmiarze, które dzielą wagi w jednym wymiarze czasowym są znane jako sieci neuronowe (ang. *Neural Networks*) z opóźnieniem czasowym TDNN (ang. *Time Delay Neural Networks*). Sieci TDNN zostały wykorzystane w rozpoznawaniu fonemów (bez podpróbkiowania) [79], [80], rozpoznawaniu słów mówionych (z podpróbkiowaniem) [81], [82], rozpoznawaniu online izolowanych znaków pisma ręcznego [83] oraz weryfikacji podpisów [84]. W podrozdziale 4.3 przedstawiono przegląd dostępnych prac badawczych dotyczących zastosowania spłotowych sieci neuronowych do wyznaczania wartości liczbowych monitorowanych parametrów w sieci optycznej.

4.3 Wykorzystanie spłotowych sieci neuronowych do wyznaczania wartości liczbowych monitorowanych parametrów

Pierwszą pracą w której zastosowano spłotowe sieci neuronowe do detekcji zakłóceń w sieciach światłowodowych była praca [85]. W pracy tej sieci spłotowe wykorzystano do monitorowania dyspersji chromatycznej bez wyznaczania jej wartości liczbowej. Następnie pojawiło się kilka kolejnych prac badawczych przedstawiających możliwości zastosowania spłotowych sieci neuronowych do wspomaganie metod monitorowania wydajności optycznej sieci światłowodowych w wyznaczaniu wartości liczbowych mierzonych parametrów. Należy przy tym wyraźnie zaznaczyć, że liczba takich prac nie jest duża. Każda z prac [86]–[91] zawiera wyniki badań dla różnych formatów modulacji (np. OOK, DPSK, QPSK, PAM4, PAM8, 8QAM, 16QAM) oraz różnych prędkości transmisji (np. 10, 20, 25, 30, 60, 100 Gbit/s). W części prac wykorzystano również dodatkowo wspomniane już wcześniej techniki takie jak Asynchroniczny Histogram Amplitudy [87], Analizator Diagramów [88] oraz Wykres Oka [89].

W pracach [87]–[89] skupiono się wyłącznie na monitorowaniu szumu ASE oraz na rozpoznawaniu formatów modulacji i prędkości transmisji. W pracy [86] wykorzystano wielozadaniowy algorytm sieci spłotowych MT-DNT (ang. *Multi-Task Deep Neural Network*),

którego dodatkowym zadaniem poza monitorowaniem szumu ASE była jednoczesna klasyfikacja rodzajów modulacji oraz przepływności. Dane dla sieci splotowej pochodziły z metody AAH. Badania przeprowadzono dla modulacji PDM-QPSK, 8QAM i 16QAM, dla przepływności 20 i 30 Gbit/s. Uzyskano średni błąd wyznaczania wartości parametru OSNR na poziomie 0,58 dB w zakresach monitorowania od 10 do 22 dB, od 14 do 24 dB oraz od 17 do 26 dB. Dodatkowo zmierzono wpływ zjawiska dyspersji chromatycznej na dokładność wyznaczania wartości parametru OSNR. W przypadku wystąpienia zjawiska dyspersji chromatycznej w zakresie od 0 do 1600 ps/nm, dokładność monitorowania zjawiska szumu ASE zmieniała swoją wartość w zakresie od 0,58 dB do 0,97 dB. Do przeprowadzenia badań sieci splotowej wykorzystano zestaw danych uczących składający się z 2040 elementów. Proces uczenia sieci przeprowadzono dla wartości do 150 epok. W pracy [87] sieci splotowe zastosowano do rozpoznawania formatów modulacji (QPSK, 8PSK (ang. *Phase-Shift Keying*), 8QAM, 16QAM, 32QAM, 64QAM) oraz monitorowania zjawiska szumu ASE w zakresie od 15 do 30 dB oraz od 20 do 35 dB dla przepływności 25 Gbit/s. Dane wykorzystane w procesie uczenia sieci splotowej zostały wygenerowane przez metodę Analizatora Diagramów. Uczenie przeprowadzono dla 200 epok, dla sześciu zestawów danych uczących (dla każdej modulacji) składających się z 1600 elementów każdy. Uzyskano dokładność rozpoznawania formatów modulacji na poziomie 95% dla modulacji 64QAM oraz 99% dla pozostałych formatów. Dokładność wyznaczania wartości OSNR określono na poziomie do 0,7 dB. W trakcie badań wprowadzano zakłócenie zjawiskiem dyspersji chromatycznej w zakresie od -100 do 100 ps/nm. W pracy [88] zademonstrowano wyniki rozpoznawania formatów modulacji (RZ-OOK, NRZ-OOK, RZ-DPSK oraz 4PAM) przy równoczesnym występowaniu zjawisk szumu ASE w zakresie od 10 do 25 dB i dyspersji chromatycznej w zakresie od -100 do 100 ps/nm dla przepływności 25 Gbit/s. Dane uczące dla sieci splotowej składały się z 1600 elementów (dla każdej modulacji) i pochodziły z wykresu oczkowego. Uzyskano 100% dokładność w klasyfikacji formatów modulacji dla sieci splotowej nauczonej powyżej 31 epok.

Równoczesne monitorowanie trzech parametrów z wykorzystaniem metody ADTS przedstawiono tylko w dwóch pracach [90], [91]. Należy podkreślić, że obie prace pochodzą od tych samych autorów. Dla pierwszej pracy [90] badano OSNR w zakresie 10 - 28 dB z krokiem 2 dB, dyspersję chromatyczną w zakresie 0 - 450 ps/nm z krokiem 50 ps/nm oraz DGD w zakresie 0-10 ps z krokiem 1 ps uzyskując przy tym średni błąd monitorowania na poziomie 0,81 dB dla OSNR, 1,52 ps/nm dla dyspersji chromatycznej oraz 0,32 ps dla DGD. Architektura badanej sieci splotowej była następująca: warstwa wejściowa wykorzystująca

portrety fazy o rozdzielczości 100x100 pikseli, cztery warstwy spłotowe, trzy warstwy łączące oraz jedna warstwa w pełni połączona składająca się ze stu węzłów [91]. Proces uczenia sieci przeprowadzono w zakresie od 60 do 125 epok, dla zestawów danych składających się z przepływności 60 i 100 Gbit/s, modulacji 16QAM, 64QAM i QPSK oraz 10 wartości dyspersji chromatycznej, 10 OSNR i 11 DGD. Łącznie uzyskano 6600 obrazów (po 1100 portretów fazy na badaną modulację i zadaną przepływność). W pracy [90] nie podano szczegółowych informacji nt. dokładności wyznaczanych parametrów dla każdej przepływności i modulacji z osobna. W drugiej pracy [91] mierzono takie same parametry w takim samym zakresie i z tym samym krokiem między kolejnymi wartościami (co 50 ps/nm dla dyspersji chromatycznej, co 2 dB dla OSNR i co 1 ps dla DGD), ale dla modulacji i kodowania NRZ-OOK, RZ-OOK i NRZ-DPSK oraz przepływności 10 i 20 Gbit/s. Uzyskano średnie wartości błędów monitorowanych wielkości na poziomie 0,73 dB dla OSNR, 1,34 ps/nm dla dyspersji chromatycznej i 0,47 ps dla DGD. Dla sygnału 10 Gbit/s NRZ-OOK uzyskano średni błąd 0,47 dB dla OSNR, 1,30 ps/nm dla dyspersji chromatycznej i 0,62 ps dla DGD, natomiast dla 10 Gbit/s NRZ-DPSK uzyskano 0,38 dB dla OSNR, 1,53 ps/nm dla dyspersji chromatycznej oraz 0,48 ps dla DGD. W badaniach tych wykorzystano zestawy danych składające również z 1100 portretów fazy, a wspomniane dokładności uzyskano dla procesu uczenia sieci w zakresie od 35 do 50 epok.

Wyniki badań zaprezentowane w omówionych pracach badawczych przedstawiają duże możliwości wykorzystywania spłotowych sieci neuronowych w procesie wspomaganie metod monitorowania zarówno w wyznaczaniu wartości liczbowych parametrów, ale również rozpoznawaniu formatów modulacji czy prędkości transmisji. Pomijają jednak dużo istotnych czynników, które mogą mieć wpływ na ostateczną dokładność. Tylko w dwóch pracach monitorowane są równocześnie trzy zjawiska, natomiast w pozostałych badaniach monitoruje się tylko szum ASE oraz dodatkowo rozpoznaje się format modulacji oraz/lub prędkość transmisji. W żadnym badaniu nie poświęcono dostatecznie dużej uwagi parametrowi liczby epok, który jest bardzo ważny w trakcie procesu uczenia sieci. Zwiększenie liczby epok, powoduje zmniejszenie średniego błędu wyznaczania wartości poszczególnych zjawisk jednak wciąż nie daje pewności uzyskania małego błędu w późniejszym wykorzystaniu modeli do rozpoznawania zjawisk z zewnętrznych zestawów danych z zachowaniem wymagań stawianych technikom monitorowania wydajności optycznej. W każdej z prac proces uczenia sieci został zakończony na etapie, gdy uzyskano wysoką dokładność rozpoznawania, na podstawie weryfikacji z zestawem danych testowych, przy liczbie epok od 30 do 100. Wysoka dokładność modelu, nie oznacza jednak jego późniejszej wysokiej dokładności przy

wykorzystaniu innego zestawu danych niż testowego/walidacyjnego. Aby to ocenić konieczne jest bowiem dodatkowe przeprowadzenie badań na zewnętrznych danych, czego we wspomnianych pracach zabrakło. Dodatkowo w zaprezentowanych badaniach wykorzystano zbyt małą liczbę obrazów znajdujących się w zestawach danych, o czym wspomnieli sami autorzy prac. Wykorzystany zakres pomiarowy wydaje się zbyt szeroki, a krok między kolejnymi analizowanymi wartościami zbyt duży. Modele sieci nauczone w ten sposób okazują się być mało dokładne. Przedstawiono to we wnioskach w [87], gdzie dokładność monitorowanego parametru OSNR ze średniego błędu z 0,58 dB przy dyspersji chromatycznej równej 0 wzrosła do 0,97 dB w przypadku wystąpienia zjawiska dyspersji chromatycznej w zakresie od powyżej 0 do 1600 ps/nm.

W rozdziale 5 przedstawiono informacje o uczeniu splotowej sieci neuronowej. W wyniku przeprowadzonego procesu uczenia uzyskano modele opisujące nauczoną sieć. Posłużą one w kolejnym etapie (rozdział 6) jako gotowe modele wykorzystywane do wyznaczania wartości liczbowych parametrów opisujących równocześnie monitorowane zjawiska.

5. Uczenie spłotowej sieci neuronowej

Ogólny proces uczenia sieci spłotowej przebiegał wg. następujących etapów:

- Zamodelowanie metody ADTS w środowisku VPIphotonics i wygenerowanie portretów fazy przy równocześnie występującym zjawisku dyspersji chromatycznej, szumu ASE i przeniku optycznego w linii światłowodowej. Portrety fazy utworzą zestawy danych dla spłotowej sieci neuronowej.
- Zbudowanie spłotowych sieci neuronowych o różnej architekturze, przeprowadzenie testowych serii procesu uczenia sieci w celu wybrania najlepszej architektury oraz optymalnych ustawień.
- Przeprowadzenie właściwego procesu uczenia sieci spłotowej w wyniku, którego uzyskano gotowe modele sieci do monitorowania zjawisk dyspersji chromatycznej, przeniku i szumu ASE.
- Przeprowadzenie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska na zewnętrznych zestawach danych z wykorzystaniem gotowych modeli sieci.

W celu uzyskania danych do procesu uczenia sieci spłotowej konieczne było zamodelowanie stanowiska pomiarowego realizującego pomiary zgodnie z metodą ADTS. Aby uzyskać dobre wyniki dopasowania dla nauczanych modeli, poza wyborem odpowiedniej architektury dla budowanej sieci, należało zapewnić również odpowiednią liczbę danych w zestawach treningowych. W zależności od rozwiązywanego problemu liczba ta powinna wynosić co najmniej kilkadziesiąt tysięcy. Dodatkowo dane powinny posiadać stosunkowo równomierny rozkład wartości analizowanego zjawiska względem badanego zakresu zakłóceń. Z powodu konieczności spełnienia kryterium ilościowego liczby danych oraz ze względu na dużą elastyczność w generowaniu kombinacji zjawisk dyspersji chromatycznej, przeniku oraz szumu ASE zdecydowano się wykorzystać dedykowane środowisko symulacyjne w postaci oprogramowania VPIphotonics [41]. W wyniku symulacji uzyskano zestawy danych liczące od 40000 do 102500 portretów fazy. Przeprowadzone badania wskazały, że powyżej liczby 102500 nie uzyskuje się lepszych wyników w procesie uczenia sieci CNN. Dodatkowe parametry przyjęte w trakcie symulacji to:

- opóźnienia bitowe o wartościach 0,25; 0,5 i 1 bit,
- modulacja NRZ-OOK i NRZ-DPSK,
- przepływność 10 Gbit/s.

Wybrane modulacje wraz z przepływnością 10 Gbit/s są jednymi z podstawowych wykorzystywanych w systemach transmisji optycznej. W literaturze dostępnych jest dużo wyników dla tych modulacji i przepływności, dlatego stanowią dobry materiał do porównania z wynikami badań uzyskanymi w ramach rozprawy doktorskiej.

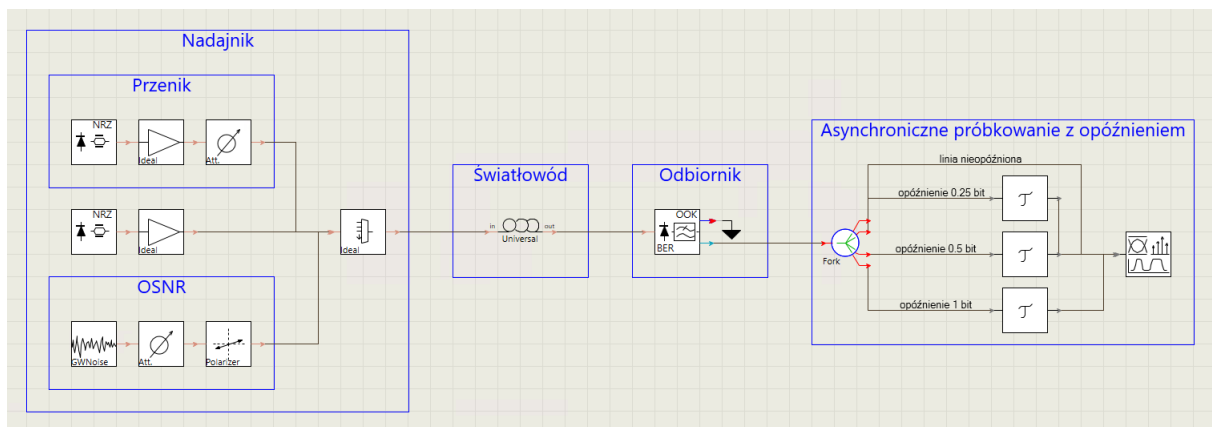
W kolejnym etapie przeprowadzono testowe serie uczenia sieci z wykorzystaniem wygenerowanych zestawów danych w celu określenia optymalnej liczby danych w zestawach uczących. Ostatecznie we właściwych badaniach użyto zestawów liczących 62000 portretów fazy. Dla zestawów, które posiadały poniżej tej liczby uzyskiwano niskie współczynniki dopasowania modeli opisujących nauczone sieci. Zestawy danych powyżej tej liczby obrazów posiadały za dużo zbieżnych wartości, co z kolei wpływało na szybkie przeuczenie sieci w trakcie jej uczenia oraz uniemożliwiało uzyskanie odpowiednio wysokich współczynników dopasowania dla modeli. Przeuczenie (przetrenowanie) oznacza, że algorytm uczy się poszczególnych przypadków zamiast ogólnych zasad. W ten sposób model będzie posiadał ograniczoną dokładność w wyznaczaniu wartości liczbowych innych niż dane znajdujące się w zestawie treningowym. W przypadku niedouczenia algorytm będzie wyznaczał wartości liczbowe z bardzo dużym błędem względem wartości rzeczywistych.

Proces uczenia sieci splotowej przeprowadzono według metodyki uczenia nadzorowanego. Dla każdego portretu fazy z zestawu danych uczących znana była zadana (oczekiwana) wartość wyjściowa zakłócenia. Rolą algorytmu uczącego było jak najdokładniejsze odwzorowanie funkcji dopasowania modelu (z jak najmniejszym błędem) do oczekiwanych danych wyjściowych.

W kolejnych podrozdziałach przedstawiono sposób przygotowania danych do procesu uczenia sieci, architekturę zbudowanej sieci i przyjęte ustawienia w procesie uczenia oraz analizę uzyskanych wyników dopasowania dla gotowych modeli. Otrzymane modele zostaną dalej wykorzystane w procesie wyznaczania wartości parametrów opisujących równocześnie występujące zjawiska zakłócającej transmisję światłowodową (rozdział 6).

5.1 Przygotowanie danych do procesu uczenia splotowej sieci neuronowej

Dane potrzebne do przeprowadzenia procesu uczenia splotowej sieci neuronowej zostały wygenerowane w oprogramowaniu symulacyjnym VPIphotonics. Zbudowano dwa modele symulacyjne realizujące technikę asynchronicznego próbkowania z opóźnieniem dla modulacji DPSK oraz OOK. Na rys. 5.1. przedstawiono schemat metody ADTS dla modulacji OOK zamodelowany w oprogramowaniu VPI.



Rys. 5.1 Schemat metody ADTS w środowisku VPIphotonics dla modulacji OOK.

Każdy model zbudowano z czterech głównych bloków funkcyjnych: nadajnika, światłowodu, odbiornika oraz asynchronicznego próbkowania z opóźnieniem. Nadajnik zbudowany jest z przestrajalnego lasera pracującego na długości fali 1550 nm, modulatora Macha-Zehndera oraz generatora sekwencji pseudolosowej PRBS (ang. *Pseudo-Random Bit Sequence*). W nadajniku zastosowano kod transmisyjny NRZ. Pozostałe bloki znajdujące się w nadajniku symulują zakłócenia sygnału występujące w trakcie transmisji danych. Blok „Przenik” odpowiedzialny jest za zjawisko przeniku wewnątrzkanałowego natomiast blok „OSNR” za szum ASE, którego źródłem jest wzmacniacz optyczny EDFA. Światłowód stanowi warstwę fizyczną sieci optycznej, w której zachodzą zjawiska (rozdział 2) ograniczające jakość i zasięg transmisji. W omawianej pracy badawczej wykorzystano bezstratny światłowód jednomodowy G652 do symulacji zjawiska dyspersji chromatycznej. Poziom dyspersji regulowano poprzez zmianę długości światłowodu. Blok odbiornika odpowiada za proces demodulacji przychodzącego sygnału optycznego i jego zamianę na sygnał elektryczny. Dla każdej z badanych modulacji wykorzystano odpowiedni blok odbiornika z biblioteki VPIphotonics. W bloku asynchronicznego próbkowania z opóźnieniem jako końcowy element modelu ADTS

znajduje się analizator, do którego poprzez rozdzielacz docierają cztery linie sygnału elektrycznego. Trzy linie są opóźnione odpowiednio o 0,25 bitu; 0,5 bitu oraz 1 bit.

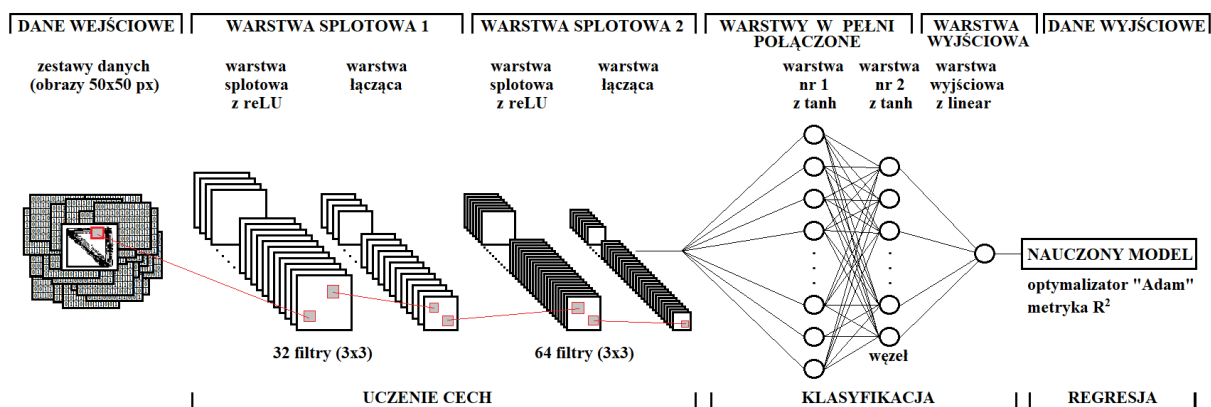
W wyniku przeprowadzonych symulacji uzyskano po 248000 przebiegów sygnału elektrycznego dla każdej z dwóch badanych modulacji. Każdy z przebiegów był zakłócony jednocześnie występującymi zjawiskami dyspersji chromatycznej (w zakresie od 0 do 2000 ps/nm), przeniku oraz szumem ASE (oba zjawiska w zakresie od 5 do 40 dB). Z otrzymanych przebiegów zbudowano sześć zestawów danych (ang. *datasets*). Zestawy budowano poprzez połączenie przebiegów nieopóźnionych z przebiegami opóźnionymi. W ten sposób otrzymano trzy zestawy po 62000 próbek każdy dla opóźnień 0,25 bitu; 0,5 bitu oraz 1 bit, dla każdej z modulacji.

Wygenerowane w ten sposób dane zostały dalej wykorzystane w procesie uczenia spłotowej sieci neuronowej. W podrozdziale 5.2 przedstawiono zbudowaną sieć oraz omówiono kryteria, na podstawie których wybrano optymalne ustawienia sieci dla procesu jej uczenia.

5.2 Budowa spłotowej sieci neuronowej oraz ustawienia przyjęte dla procesu uczenia

Splotowa sieć neuronowa została zaimplementowana w oparciu o biblioteki TensorFlow [92] oraz TFLearn [93]. TensorFlow jest biblioteką programistyczną typu „open source” wykorzystywaną w uczeniu maszynowym, w tym i głębokich sieciach neuronowych. Główną zaletą biblioteki jest możliwość współpracy z kartami graficznymi. Poprzez wykorzystanie mocy obliczeniowych kart możliwe jest znaczące przyśpieszenie obliczeń w procesie uczenia sieci. Biblioteka TFLearn jest zbudowana na bazie TensorFlow. Pozwala na szybkie budowanie sieci spłotowych, ich uczenie oraz testowanie.

Przed rozpoczęciem właściwego procesu uczenia, zbudowano kilka prototypów sieci, żeby ocenić wpływ ich architektury na otrzymywane wyniki uczenia. Ostatecznie po przeprowadzeniu kilkudziesięciu serii testów procesu uczenia dla sieci z dwoma, trzema oraz czterema warstwami spłotowymi za optymalną architekturę sieci dla rozpatrywanego problemu uznano tę z dwiema warstwami spłotowymi. Większa liczba warstw spłotowych znacznie wydłużała czas niezbędny do nauczenia sieci i jednocześnie obniżała współczynnik dopasowania modelu, nie powodując wzrostu dokładności ich działania. Na rys. 5.2. przedstawiono architekturę zbudowanej sieci spłotowej.



Rys. 5.2 Architektura zbudowanej splotowej sieci neuronowej.

Pierwszy element sieci stanowią zestawy danych wejściowych składające się z 62000 binarnych obrazów o rozdzielczości 50 na 50 pikseli. Przed rozpoczęciem procesu uczenia sieci, dane są rozdzielane poprzez algorytm na zestaw uczący oraz testowy. Kolejnymi elementami sieci są dwie warstwy splotowe, które w nomenklaturze sieci splotowych określane są jako warstwy ukryte (głębokie). Pierwsza warstwa splotowa zbudowana jest z 32 filtrów splotowych o wymiarach 3x3, natomiast druga z 64 filtrów o takich samych wymiarach jak pierwsza. W każdej z warstw splotowych zastosowano funkcję aktywacji ReLU. Końcowym elementem każdej z warstw splotowych jest warstwa łącząca. W pierwszej warstwie łączącej następuje zmniejszenie wymiarów macierzy obrazu z 50x50 pikseli do 25x25 pikseli i przekazanie jej na wejście drugiej warstwy splotowej. W drugiej warstwie łączącej macierz o wymiarach 25x25 pikseli zmniejszana jest do 13x13 pikseli. Następnie macierz zostaje spłaszczona do jednego wymiaru i przekazana jako wejście do warstw w pełni połączonych. W dwóch pierwszych warstwach w pełni połączonych jako funkcję aktywacji zastosowano tangens hiperboliczny. Te dwie warstwy są również zaliczane do warstw ukrytych. Ostatni węzeł wraz z liniową funkcją aktywacji stanowi warstwę wyjściową sieci i decyduje o ostatecznym wyniku klasyfikacji obrazu do poszczególnej klasy zakłóceń (jest to cecha różniąca sieć zaprezentowaną w rozprawie doktorskiej względem sieci LeNet-5 przedstawionej w podrozdziale 4.2). W przeprowadzonych badaniach nie skupiono się jednak na problemach klasyfikacji, a na wyznaczeniu wartości parametrów występujących zjawisk. Z tego względu zastosowano jeszcze jedną warstwę regresji, w której wykorzystano optymalizator „ADAM” (ang. *Adaptive Moment Estimation*) oraz metrykę R^2 , na podstawie której ocenia się jakość dopasowania gotowego modelu. W trakcie badań empirycznych określono również optymalne wartości dla parametrów: współczynnik uczenia, rozmiar paczki danych oraz liczba epok. W tabeli 5.1 przedstawiono najważniejsze ustawienia wykorzystane we właściwym procesie uczenia sieci splotowej. Nazwy wszystkich parametrów zamieszczono

w języku angielskim oraz polskim. Dodatkowo pod tabelą 5.1 zamieszczono definicję poszczególnych ustawień.

Tabela 5.1 Ustawienia przyjęte w trakcie procesu uczenia sieci spłotowej.

Nazwa parametru		Wartości
Dataset	Zestaw danych	62000 (obrazów o rozdzielczości 50 na 50 pikseli)
Test size value	Zestaw testowy	9300 obrazów (15% z 62000)
Batch size	Rozmiar paczki danych	100
Learning rate	Współczynnik uczenia	0,0001
Epoch number	Liczba epok / iteracji	50, 75, 100, 150, 250, 350, 450, 550, 650, 750, 850, 950, 1000
Conv 2d	Liczba filtrów spłotowych w danej warstwie ukrytej	32 (dla pierwszej warstwy) / 64 (dla drugiej warstwy)
Fully connected	Warstwy w pełni połączone	384/128, 512/256, 512/128, 384/256, 384/64, 384/384, 512/512
Optimizer	Algorytm optymalizacji	Adam

Dataset – jest to zestaw danych wykorzystywany w procesie uczenia sieci. W omawianej pracy doktorskiej zestawy składają się z 62000 binarnych obrazów. Każdy obraz zapisany jest w postaci dwuwymiarowej macierzy, która przyjmuje wartości 0 lub 1. Do algorytmu uczenia macierz przekazywana jest w postaci jednowymiarowego wektora o długości równej iloczynowi wysokości i szerokości obrazu. Dla przeprowadzonych badań zbudowano po trzy zestawy danych (0,25 bit; 0,5 bit oraz 1 bit) dla każdej modulacji (DPSK, OOK).

Test size value – jest to parametr określający jaka liczba obrazów z całego zestawu danych, zostanie przeznaczona na zestaw testowy. Przed rozpoczęciem procesu uczenia algorytm dzieli zestaw danych na zestaw treningowy (uczący) i testowy (walidacyjny). Zestaw testowy wykorzystywany jest pod koniec procesu uczenia sieci w celu sprawdzenia dokładności gotowego modelu. Obrazy znajdujące się w zestawie testowym nie biorą udziału w procesie uczenia.

Batch size – zestaw danych podzielony jest na paczki, które są kolejno przekazywane do algorytmu uczącego. Pod koniec przetwarzania każdej paczki algorytm dokonuje predykcji z wykorzystaniem modelu opisującego uczoną sieć. Następuje porównanie wartości obliczonych z wartościami oczekiwanymi i obliczany jest błąd uczenia. Na podstawie tego błędu następuje aktualizacja algorytmu, który ulepsza nauczany model w kolejnej iteracji, z wykorzystaniem kolejnej paczki. W każdej paczce znajduje się ustalona z góry liczba obrazów. Parametr batch size określa liczbę obrazów znajdujących się w takiej paczce.

Learning rate – jest to liczba zmiennoprzecinkowa z zakresu od 10^{-6} do 1 odpowiadająca za szybkość uczenia sieci spłotowej. Standardowo parametr ten przyjmuje wartość 0,1 lub 0,01;

jednak powinien być on ustalany zawsze w sposób indywidualny w zależności od rozwiązywanego problemu i wykorzystywanego zestawu danych. Parametr ten określa się w sposób empiryczny. Wysoka wartość przyspieszy proces jednak najprawdopodobniej zwiększy też błąd uczenia sieci. Niska wartość może znacząco spowolnić proces, jednak nie zawsze będzie wpływać pozytywnie na końcowy wynik uczenia.

Epoch number – jest to liczba określająca, ile razy algorytm wykorzysta zestaw treningowy w procesie uczenia sieci. Jedna epoka oznacza, że każda próbka z zestawu treningowego będzie miała możliwość zaktualizować jeden raz wewnętrzne parametry modelu uczonego. Liczbę epok ustawia się na setki lub tysiące, co umożliwi algorytmowi uczącemu działanie, dopóki błąd modelu nie zostanie dostatecznie zminimalizowany. Parametr ten służy również do konstruowania wykresów zwanych „krzywymi uczenia”, które pozwalają na ocenę czy model został przeuczony bądź niedouczony. W prezentowanej pracy zastosowano inne podejście, a liczbę epok ograniczono do 1000, ponieważ przy większej liczbie (1100, 1200, 1400, 1500, 1800, 2000, 4000, 6000, 9000) następowało przeuczenie modeli.

Conv 2d – w bibliotece TFLearn funkcja `conv_2d` odpowiedzialna jest za stworzenie warstwy splotowej. W prezentowanej pracy zbudowano sieć składającą się z dwóch warstw splotowych, a parametr Conv 2d odpowiedzialny jest za liczbę filtrów splotowych wykorzystanych w budowie poszczególnych warstw. Pierwsza warstwa zbudowana została z 32 filtrów splotowych, natomiast druga z 64 filtrów o rozmiarze 3x3 każda i kroku przejścia 1. W obu warstwach zastosowano popularną funkcję aktywacji ReLU. Po każdej z warstw aktywacji zastosowano warstwę łączącą z filtrem rozmiarze 2x2 i kroku przejścia 1.

Fully connected – zbudowana sieć splotowa posiada trzy w pełni połączone warstwy. Dwie z nich wykorzystują funkcję aktywacji tanh i posiadają zadaną liczbę jednostek tzw. węzłów, które są testowane parami w trakcie procesu uczenia sieci (np. 384/128). Trzecia warstwa w pełni połączona zbudowana jest z jednej jednostki z liniową funkcją aktywacji i zapewnia wartość wyjściową z nauczonej sieci splotowej.

Optimizer – w trakcie procesu uczenia sieci wykorzystano wydajny algorytm optymalizacji Adam, który dobrze sprawdza się w zadaniach z dużym zbiorem testowym.

Współczynnik determinacji R^2 – jest to jedna z miar jakości dopasowania modelu do danych uczących. Współczynnik determinacji przyjmuje wartości z przedziału od 0 do 1. Dopasowanie modelu jest tym lepsze, im wartość metryki jest bliższa jedności.

W następnym podrozdziale 5.3 przedstawiono wyniki uczenia sieci z wykorzystaniem zestawów danych pochodzących z metody ADTS.

5.3 Uczenie sieci splotowej z wykorzystaniem danych pochodzących z metody asynchronicznego próbkowania z opóźnieniem

Proces uczenia sieci splotowej przeprowadzono dla ustawień zamieszczonych w tabeli 5.1. Jak już wspomniano w poprzednich podrozdziałach, część ustawień określono na podstawie wyników uzyskanych z testowych serii uczenia sieci. Ustalenie wpływu innych ustawień na wyniki uczenia sieci takich jak liczba epok oraz liczba węzłów w warstwach w pełni połączonych było dodatkowym celem prowadzonych badań. Proces uczenia przeprowadzono według kolejności z tabeli 5.2. Badania wykonano najpierw dla opóźnienia 0,25 bitu; następnie 0,5 bitu, a na końcu 1 bitu. Sieć uczono na rozpoznawanie zjawisk dyspersji chromatycznej, przeniku oraz szumu ASE (wyrażonego parametrem OSNR) dla modulacji DPSK i OOK.

Tabela 5.2 Kolejność przeprowadzenia procesu uczenia splotowej sieci neuronowej.

L.p.	Zjawisko	Modulacja	Opóźnienie	L.p.	Zjawisko	Modulacja	Opóźnienie
1	CD	DPSK	0,25 bit	10	przenik	OOK	0,5 bit
2		OOK		11	szum ASE	DPSK	
3	przenik	DPSK		12		OOK	
4		OOK		13	CD	DPSK	1 bit
5	szum ASE	DPSK		14		OOK	
6		OOK		15	przenik	DPSK	
7	CD	DPSK	16	OOK			
8		OOK	17	szum ASE	DPSK		
9	przenik	DPSK	18		OOK		

W tabelach 5.3. - 5.20 zamieszczono wyniki uczenia sieci splotowej. Na każdy jeden przeprowadzony proces uczenia przypadają dwie komórki. Pierwsza w postaci np. „50, R^2 ” informuje, że uczenie przeprowadzono dla 50 epok, a wartość współczynnika dopasowania gotowego modelu wynosi R^2 . Druga komórka „śr. błąd” informuje o średniej wartości błędu uzyskanej dla modelu. Oblicza się go w ostatnim etapie uczenia sieci na podstawie wyników uzyskanych po przetestowaniu modelu przez zestaw testowy. „Numer zestawu” zamieszczony w nagłówku każdej tabeli służy jako numer porządkowy przyjętej konfiguracji i informuje o liczbie węzłów wykorzystanych w warstwach w pełni połączonych. W każdej tabeli dokonano oznaczenia najlepszych parametrów dla poszczególnych zestawów: współczynnik dopasowania R^2 podkreślono oraz pogrubiono, błąd uczenia pogrubiono oraz umieszczono na

żółtym tle. Najniższą średnią wartość błędu dla wszystkich zestawów oraz równocześnie najlepszy wynik uczenia pogrubiono oraz umieszczono na zielonym tle.

W tabeli 5.3 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji DPSK i opóźnienia 0,25 bit.

Tabela 5.3 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999979	0,999981	0,999980	0,999979	0,999979	0,999978	0,999979
śr. błąd	1,973700	1,834200	1,888200	1,879500	1,899000	1,945600	1,887200
75, R^2	0,999983	0,999984	0,999984	0,999983	0,999982	0,999983	0,999983
śr. błąd	1,684900	1,630300	1,602800	1,780100	1,771700	1,678800	1,761200
100, R^2	0,999984	0,999985	0,999985	0,999985	0,999984	0,999985	0,999984
śr. błąd	1,672000	1,582000	1,512900	1,676100	1,635000	1,612400	1,614200
150, R^2	0,999986	0,999986	0,999986	<u>0,999987</u>	0,999985	0,999986	0,999986
śr. błąd	1,540500	1,4694700	1,528000	1,397600	1,553600	1,476800	1,558100
250, R^2	0,999987	0,999986	0,999980	<u>0,999987</u>	<u>0,999987</u>	0,999986	0,999986
śr. błąd	1,387700	1,480700	1,421400	1,442600	1,420900	1,469400	1,531300
350, R^2	0,999985	0,999986	0,999985	0,999986	0,999985	0,999986	0,9999857
śr. błąd	1,497160	1,599600	1,541700	1,498200	1,510200	1,531700	1,533100
450, R^2	0,999982	0,999983	0,999982	0,999984	0,999981	0,999984	0,999982
śr. błąd	1,73120	1,833000	1,735100	1,704700	1,718000	1,610800	1,787200
550, R^2	0,998398	0,997976	0,998457	0,998774	0,998650	0,999135	0,998877
śr. błąd	21,11410	22,64040	23,43510	17,25700	22,00020	14,79470	18,95770
650, R^2	<u>0,999988</u>	<u>0,999987</u>	<u>0,999987</u>	<u>0,999987</u>	0,999986	<u>0,999987</u>	<u>0,999987</u>
śr. błąd	1,315500	1,364900	1,354900	1,336400	1,396300	1,373900	1,420000
750, R^2	<u>0,999988</u>	0,999986	<u>0,999987</u>	<u>0,999987</u>	0,999985	0,999986	0,999986
śr. błąd	1,317900	1,487300	1,445700	1,367200	1,413900	1,435800	1,501500
850, R^2	0,999987	0,999986	<u>0,999987</u>	0,999986	0,999986	0,999984	0,999983
śr. błąd	1,426600	1,509500	1,415200	1,448400	1,428900	1,652800	1,644700
950, R^2	0,999984	0,999984	0,999983	0,999985	0,999982	0,999983	0,999981
śr. błąd	1,611500	1,659100	1,603400	1,554700	1,659900	1,675200	1,800400
1000, R^2	0,999984	0,999981	0,999980	0,999981	0,999982	0,999978	0,999980
śr. Błąd	1,625300	1,813700	1,713000	1,848300	1,663600	2,009300	1,834100

Podsumowanie danych z tabeli 5.3:

Dla większości przypadków badanych zestawów najlepsze wartości współczynników dopasowania modeli uzyskano naprzemiennie dla sieci nauczonych dla 650 oraz 750 epok. W przypadku zestawów 4 i 5 porównywalne wartości współczynników dopasowania $R^2 = 0,999987$ otrzymano dla 150 oraz 250 epok, jednak przy jednoczesnych wyższych średnich wartościach błędów. Najlepszy współczynnik dopasowania modelu

o wartości $R^2 = 0,999988$ spośród wszystkich badanych zestawów uzyskano dla zestawu nr 1 dla 650 oraz 750 epok. Dla 650 epok uzyskano jednocześnie najniższy średni błąd estymacji dyspersji chromatycznej o wartości 1,3155 ps/nm. W każdym przypadku powyżej 650 epok zaobserwowano wzrost średniej wartości błędu badanego zjawiska co może oznaczać przetrenowanie sieci.

W tabeli 5.4 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji OOK i opóźnienia 0,25 bit.

Tabela 5.4 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczenia wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999966	0,999964	0,999966	0,999959	0,999960	0,999953	0,999959
śr. Błąd	2,101700	2,257700	2,058800	2,528100	2,228900	2,591800	2,249100
75, R^2	0,999967	0,999970	0,999969	0,999968	0,999966	0,999964	0,999968
śr. Błąd	1,999600	1,948100	1,865500	1,969200	2,019500	2,206100	1,993700
100, R^2	0,999724	0,999974	0,999970	0,999970	0,999969	0,999967	0,999969
śr. błąd	1,815400	1,787500	1,909200	1,861700	1,945500	1,928500	1,848400
150, R^2	0,999972	0,999973	0,999972	0,999972	0,999968	0,999972	0,999972
śr. błąd	1,856400	1,799700	1,715700	1,754700	1,878000	1,741700	1,837500
250, R^2	0,999973	0,999971	0,999970	0,999973	0,999966	0,999973	0,999973
śr. błąd	1,788600	1,952800	1,708900	1,745000	1,848600	1,672800	1,726400
350, R^2	0,999969	0,999975	0,999973	0,999975	0,999968	0,999972	0,999975
śr. błąd	1,824800	1,724500	1,725200	1,764400	1,872300	1,744700	1,724800
450, R^2	0,999968	0,999966	0,999963	0,999967	0,999961	0,999968	0,999968
śr. błąd	2,132800	2,145400	2,146800	1,989300	2,083000	2,035100	2,128800
550, R^2	0,998407	0,998708	0,998540	0,998648	0,998813	0,998311	0,997811
śr. błąd	23,06280	20,74190	20,54530	19,25750	21,12220	21,98080	22,93300
650, R^2	0,999970	0,999971	0,999971	0,999976	0,999972	0,999973	0,999973
śr. błąd	1,650000	1,690800	1,6481	1,609900	1,734600	1,647000	1,680000
750, R^2	0,999969	0,999973	0,999973	0,999969	0,999970	0,999975	0,999966
śr. błąd	1,670900	1,713300	1,673000	1,788100	1,725300	1,663100	1,814100
850, R^2	0,999970	0,999972	0,999969	0,999967	0,999970	0,999973	0,999973
śr. błąd	1,669300	1,854300	1,858500	1,769600	1,796200	1,748300	1,793600
950, R^2	0,999970	0,999965	0,999967	0,999970	0,999964	0,999964	0,999963
śr. błąd	1,877500	2,164900	1,970600	1,907900	1,929300	1,929300	2,022000
1000, R^2	0,999959	0,999967	0,999963	0,999960	0,999963	0,999964	0,999958
śr. błąd	2,121400	2,267600	2,113800	2,135300	2,163500	2,126500	2,513800

Podsumowanie danych z tabeli 5.4:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano dla 250, 350, 650 oraz 750 epok, jednak dla wyższej liczby epok otrzymano niższe

średnie wartości błędów. Najlepszy współczynnik dopasowania modelu o wartości $R^2 = 0,999976$ oraz najniższy średni błąd estymacji dyspersji chromatycznej o wartości 1,6099 ps/nm uzyskano dla zestawu nr 4 dla 650 epok. Dla 6 z 7 zestawów powyżej 650 epok zaobserwowano wzrost średniej wartości błędu badanego zjawiska co może oznaczać przetrenowanie sieci.

W tabeli 5.5 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji DPSK i opóźnienia 0,25 bit.

Tabela 5.5 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia splotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999510	0,999490	0,999491	0,999461	0,999512	0,999482	0,999458
śr. Błąd	0,109700	0,114200	0,114900	0,117200	0,112500	0,126000	0,127000
75, R^2	0,999542	0,999542	0,999567	0,999542	0,999548	0,999536	0,999511
śr. Błąd	0,100100	0,097800	0,095400	0,110300	0,098900	0,103400	0,106200
100, R^2	0,999563	0,999537	0,999527	0,999529	<u>0,999577</u>	0,999544	0,999515
śr. błąd	0,089900	0,096600	0,093800	0,095600	0,095900	0,095700	0,100600
150, R^2	0,999546	<u>0,999570</u>	0,999567	0,999559	0,999571	0,999541	0,999528
śr. błąd	0,089500	0,084600	0,087900	0,095100	0,090300	0,091000	0,090000
250, R^2	<u>0,999588</u>	0,999565	<u>0,999571</u>	0,999561	0,999540	0,999515	0,999523
śr. błąd	0,085800	0,085600	0,088200	0,087800	0,091700	0,087000	0,087400
350, R^2	0,999536	0,999547	0,999561	<u>0,999578</u>	0,999554	0,999545	0,999548
śr. błąd	0,087800	0,087300	0,086000	0,084500	0,087800	0,090100	0,087500
450, R^2	0,999532	0,999534	0,999495	0,999532	0,999531	0,999529	0,999523
śr. błąd	0,092800	0,088000	0,091900	0,089400	0,092400	0,089800	0,097800
550, R^2	0,997968	0,997911	0,997566	0,998338	0,997841	0,998056	0,997835
śr. błąd	0,399500	0,388500	0,415300	0,334300	0,405500	0,352900	0,367000
650, R^2	0,999551	0,999481	0,999522	0,999545	0,999547	0,999549	0,999537
śr. błąd	0,081800	0,084800	0,084600	0,083000	0,081800	0,082800	0,080800
750, R^2	0,999546	0,999537	0,999549	0,999510	0,999556	<u>0,999561</u>	0,999515
śr. błąd	0,083500	0,083600	0,081700	0,084200	0,083900	0,084100	0,082900
850, R^2	0,999555	0,999521	0,999532	0,999497	0,999497	0,999537	<u>0,999550</u>
śr. błąd	0,085200	0,085700	0,085600	0,083500	0,086900	0,085300	0,082900
950, R^2	0,999566	0,999496	0,999524	0,999526	0,999567	0,999542	0,999541
śr. błąd	0,087000	0,090600	0,087500	0,086400	0,086400	0,087300	0,087000
1000, R^2	0,999511	0,999518	0,999524	0,999477	0,999518	0,999528	0,999481
śr. błąd	0,093400	0,088700	0,093400	0,093000	0,093600	0,090700	0,098700

Podsumowanie danych z tabeli 5.5:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów (5 z 7) uzyskano dla mniejszej liczby epok (100 – 350). Różnice względem modeli z większą

liczbą epok są jednak nieznaczące. Najwyższą wartość $R^2 = 0,999588$ osiągnięto dla zestawu nr 1 dla 250 epok. Najniższe średnie wartości błędów estymacji zjawiska przeniku dla poszczególnych zestawów uzyskano dla 650 oraz 750 epok. Najniższą średnią wartość błędu 0,0808 dB uzyskano dla modelu z zestawu nr 7 dla 650 epok.

W tabeli 5.6 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji OOK i opóźnienia 0,25 bit.

Tabela 5.6 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędów wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,983296	0,983793	0,982553	0,983540	0,982990	0,983714	0,983743
śr. Błąd	0,392500	0,3977	0,398400	0,382500	0,367200	0,463300	0,371000
75, R^2	0,985036	0,984768	0,983492	0,983840	0,984629	0,983311	0,984059
śr. Błąd	0,318000	0,361200	0,354700	0,343300	0,329600	0,376000	0,425400
100, R^2	0,984020	0,982491	0,985959	0,984459	0,985089	0,984012	0,984544
śr. błąd	0,320700	0,327500	0,297800	0,333300	0,302600	0,316900	0,304500
150, R^2	0,985043	0,983731	0,985005	0,984391	0,986383	0,985613	0,984785
śr. błąd	0,278000	0,303300	0,278400	0,298800	0,277600	0,282600	0,288400
250, R^2	0,985713	0,985448	0,984351	0,985273	0,986430	0,986101	0,984667
śr. błąd	0,265100	0,277400	0,284300	0,275600	0,265100	0,264400	0,300000
350, R^2	0,984890	0,985470	0,985185	0,986150	0,985737	0,985627	0,984243
śr. błąd	0,276500	0,291300	0,272000	0,285700	0,269800	0,269000	0,278900
450, R^2	0,985646	0,983280	0,985780	0,983838	0,985206	0,985429	0,985152
śr. błąd	0,360200	0,293800	0,269200	0,291900	0,276000	0,270200	0,270200
550, R^2	0,983819	0,984712	0,983159	0,984654	0,985223	0,983653	0,984815
śr. błąd	0,574700	0,538800	0,561400	0,538400	0,558700	0,562400	0,521675
650, R^2	0,985635	0,985630	0,983293	0,985268	0,986184	0,986271	0,984342
śr. błąd	0,254900	0,258700	0,274200	0,257400	0,258200	0,259200	0,271500
750, R^2	0,985481	0,983860	0,985226	0,985668	0,984154	0,986116	0,985014
śr. błąd	0,266400	0,273200	0,267200	0,263000	0,264500	0,256300	0,270500
850, R^2	0,985956	0,984392	0,983886	0,985168	0,985790	0,985008	0,984648
śr. błąd	0,261800	0,269300	0,267800	0,264900	0,261000	0,276300	0,268000
950, R^2	0,984340	0,985604	0,985413	0,984766	0,986037	0,985736	0,983986
śr. błąd	0,268700	0,261600	0,271900	0,271500	0,269900	0,262900	0,289500
1000, R^2	0,985066	0,984366	0,984134	0,984547	0,985317	0,986155	0,985609
śr. błąd	0,271200	0,279200	0,276200	0,271800	0,270200	0,263600	0,279300

Podsumowanie danych z tabeli 5.6:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano dla różnej liczby epok. Najwyższą wartość $R^2 = 0,986430$ uzyskano dla zestawu nr 5 dla 250 epok. Najniższe średnie wartości błędów estymacji zjawiska przeniku otrzymano

dla 650 i 750 epok (6 z 7 zestawów). Najniższą średnią wartość błędu 0,2549 dB uzyskano dla modelu z zestawu nr 1 dla 650 epok. Dla większości zestawów powyżej 650 epok zaobserwowano lekkie pogorszenie średniej wartości błędów uzyskanych modeli. W większości przypadków średni błąd ustalał się jednak w okolicach wartości 0,27 dB. W tabeli 5.7 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji DPSK i opóźnienia 0,25 bit.

Tabela 5.7 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,981816	0,980633	0,981458	0,978804	0,981579	0,977615	0,979970
śr. błąd	0,777400	0,799900	0,770900	0,829900	0,767800	0,879900	0,868300
75, R^2	0,981635	0,982677	0,983223	0,981973	0,983088	0,981638	0,979829
śr. błąd	0,758400	0,737800	0,723300	0,755000	0,728900	0,761200	0,819700
100, R^2	0,981632	0,981484	0,983360	0,982898	0,982889	0,980946	0,981514
śr. błąd	0,751200	0,753900	0,706200	0,731900	0,721000	0,757400	0,757000
150, R^2	0,984415	0,982033	0,983562	0,982265	0,984112	0,981988	0,983130
śr. błąd	0,676900	0,733100	0,699700	0,728900	0,690900	0,740100	0,711600
250, R^2	0,983239	0,984350	0,984050	0,983709	0,984362	0,982936	0,981435
śr. błąd	0,698700	0,675500	0,681900	0,695500	0,673800	0,718200	0,733900
350, R^2	0,984587	0,983459	0,984589	0,983146	0,984282	0,984845	0,981846
śr. błąd	0,671600	0,700500	0,666200	0,703000	0,678600	0,681400	0,726700
450, R^2	0,984553	0,983013	0,984508	0,983726	0,984249	0,984635	0,981807
śr. błąd	0,680900	0,700400	0,668200	0,699100	0,683100	0,671500	0,729700
550, R^2	0,981619	0,981171	0,982674	0,980214	0,979989	0,981352	0,979966
śr. błąd	0,939200	0,869000	0,913000	0,900200	0,970900	0,858800	0,9172
650, R^2	0,983979	0,981535	0,984307	0,984910	0,984936	0,983923	0,983280
śr. błąd	0,675400	0,722200	0,664000	0,667700	0,660700	0,674500	0,688900
750, R^2	0,984142	0,982920	0,983986	0,983960	0,984556	0,982659	0,983157
śr. błąd	0,671300	0,697400	0,670300	0,679400	0,665000	0,707300	0,690800
850, R^2	0,984218	0,982118	0,983543	0,984129	0,984103	0,982990	0,981214
śr. błąd	0,669900	0,709400	0,679500	0,675900	0,667900	0,699800	0,728900
950, R^2	0,984297	0,983091	0,983395	0,983714	0,984425	0,983292	0,981716
śr. błąd	0,670800	0,691600	0,681000	0,685400	0,673200	0,688700	0,723000
1000, R^2	0,983729	0,982740	0,984075	0,983398	0,984279	0,983019	0,981530
śr. błąd	0,684200	0,694000	0,674100	0,696900	0,676100	0,693400	0,729800

Podsumowanie danych z tabeli 5.7:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano dla 250, 350 oraz 650 epok. Najniższe średnie wartości błędów uzyskano w większości przypadków dla wyższej liczby epok (4 z 5 dotyczyły 650 epok). Najwyższą

wartość współczynnika $R^2 = 0,984936$ oraz jednoczesny najniższy średni błąd estymacji o wartości 0,6607 dB uzyskano dla modelu z zestawu nr 5 dla 650 epok. Dla większości przypadków po uzyskaniu przez dany zestaw najniższej średniej wartości błędu, wraz ze wzrostem liczby epok następował wzrost błędu co może oznaczać przetrenowanie sieci.

W tabeli 5.8 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji OOK i opóźnienia 0,25 bit.

Tabela 5.8 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,986431	0,987230	0,986742	0,984998	0,986798	0,985759	0,985397
śr. Błąd	0,666100	0,599600	0,635100	0,680700	0,620400	0,634000	0,637300
75, R^2	0,987894	0,987965	0,988462	0,986144	0,986156	0,987820	0,984756
śr. Błąd	0,593800	0,560300	0,533400	0,623600	0,592500	0,563900	0,620100
100, R^2	0,986706	0,987673	0,987357	0,984961	0,988360	0,986549	0,986996
śr. błąd	0,580200	0,568000	0,555700	0,620500	0,536800	0,610400	0,580000
150, R^2	0,988815	0,986996	0,988775	0,987522	0,989216	0,987014	0,986613
śr. błąd	0,528300	0,552100	0,517000	0,545100	0,515300	0,564700	0,570000
250, R^2	0,989001	0,987848	0,988712	0,988694	0,989313	0,988032	0,988194
śr. błąd	0,508300	0,523700	0,502100	0,515900	0,498200	0,528300	0,532400
350, R^2	0,989090	0,988321	0,989323	0,988348	0,989115	0,988945	0,986424
śr. błąd	0,501000	0,512700	0,501700	0,517900	0,497800	0,532100	0,562300
450, R^2	0,989675	0,988946	0,988317	0,989344	0,988936	0,989192	0,986481
śr. błąd	0,492600	0,503100	0,503400	0,499500	0,504600	0,502100	0,570500
550, R^2	0,985814	0,985657	0,985102	0,986390	0,985749	0,985705	0,984833
śr. błąd	0,807200	0,762500	0,807100	0,733300	0,819200	0,832100	0,798300
650, R^2	0,989758	0,988312	0,989180	0,989132	0,989010	0,988735	0,987119
śr. błąd	0,483200	0,500900	0,485200	0,485800	0,492800	0,500600	0,528400
750, R^2	0,988795	0,987287	0,988038	0,989324	0,989125	0,988800	0,988009
śr. błąd	0,498600	0,513300	0,496400	0,488000	0,488400	0,498600	0,504300
850, R^2	0,989493	0,987363	0,989208	0,988985	0,989430	0,988894	0,986670
śr. błąd	0,480300	0,508200	0,483300	0,489900	0,480300	0,491100	0,523800
950, R^2	0,989270	0,986551	0,988680	0,988817	0,988821	0,988000	0,986611
śr. błąd	0,488300	0,536700	0,496800	0,491300	0,492800	0,510700	0,527300
1000, R^2	0,988060	0,987647	0,988844	0,988425	0,988625	0,988077	0,987343
śr. błąd	0,509800	0,517400	0,500300	0,507200	0,500700	0,514900	0,525100

Podsumowanie danych z tabeli 5.8:

Najlepsze wartości współczynników dopasowania dla poszczególnych zestawów uzyskano w większości przypadków (5 z 7) dla modeli z zakresu 250 – 450 epok. Najwyższą wartość $R^2 = 0,989758$ otrzymano dla zestawu nr 1 dla 650 epok. Najniższe średnie wartości błędów

otrzymano dla modeli sieci nauczonych dla 650 epok (2 razy), 750 (1 raz) oraz 850 (4 razy). Najniższy średni błąd o wartości 0,4803 dB otrzymano dla zestawów nr 1 i nr 5 dla 850 epok. Dla większej liczby epok powyżej 850 (lub 650) w większości przypadków obserwowano wzrost średniej wartości błędu co może oznaczać przetrenowanie sieci.

W tabeli 5.9 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji DPSK i opóźnienia 0,5 bit.

Tabela 5.9 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999984	0,999984	0,999985	0,999984	0,999982	0,999983	0,999981
śr. Błąd	1,699500	1,656900	1,593300	1,610100	1,754500	1,748900	1,864300
75, R^2	0,999986	0,999987	0,999988	0,999986	0,999983	0,999985	0,999983
śr. Błąd	1,508200	1,396600	1,410200	1,498700	1,604600	1,638300	1,833400
100, R^2	0,999987	0,999988	0,999987	0,999987	0,999986	0,999987	0,99998
śr. błąd	1,413800	1,344500	1,486800	1,444300	1,528500	1,436100	1,476900
150, R^2	0,999988	0,999988	0,999988	0,999988	0,999987	0,999988	0,999989
śr. błąd	1,369900	1,390000	1,362700	1,305800	1,470700	1,382900	1,286600
250, R^2	0,999988	0,999988	0,999988	0,999989	0,999986	0,999988	0,999987
śr. błąd	1,313100	1,345900	1,285900	1,363000	1,480100	1,355500	1,362100
350, R^2	0,999987	0,999987	0,999987	0,999988	0,999987	0,999988	0,999987
śr. błąd	1,412300	1,418400	1,431800	1,347700	1,389100	1,355700	1,472300
450, R^2	0,999984	0,999981	0,999985	0,999983	0,999979	0,999985	0,999984
śr. błąd	1,593700	1,760400	1,540800	1,712400	1,846500	1,590400	1,664800
550, R^2	0,998503	0,998106	0,998593	0,998752	0,998617	0,998920	0,998729
śr. błąd	21,78590	19,45460	23,60370	19,0761	21,14310	17,542100	17,562300
650, R^2	0,999989	0,999988	0,999988	0,999989	0,999988	0,999988	0,999988
śr. błąd	1,240800	1,302100	1,260700	1,262800	1,341100	1,337100	1,472000
750, R^2	0,999987	0,999988	0,999988	0,999988	0,999987	0,999988	0,999988
śr. błąd	1,291200	1,335700	1,305400	1,353200	1,363100	1,350400	1,346800
850, R^2	0,999987	0,999987	0,999986	0,999987	0,999985	0,999984	0,999984
śr. błąd	1,324800	1,378800	1,416400	1,352500	1,441800	1,593400	1,591900
950, R^2	0,999984	0,999986	0,999985	0,999987	0,999985	0,999983	0,999982
śr. błąd	1,618200	1,549000	1,548300	1,494400	1,510200	1,641100	1,709700
1000, R^2	0,999981	0,999985	0,999984	0,999982	0,999980	0,999980	0,999978
śr. błąd	1,732300	1,607500	1,732200	1,763000	1,827100	1,880000	1,989700

Podsumowanie danych z tabeli 5.9:

Najlepsze wartości współczynników dopasowania modeli i średnie wartości błędów dla poszczególnych zestawów uzyskano w większości przypadków dla 650 epok. Dla zestawów 2, 3, 4, 6 uzyskano takie same współczynniki dopasowania dla niższych epok, jednak przy

wyraźnie wyższym średnim błędzie. Dla zestawu nr 1 dla 650 epok uzyskano model z najwyższym współczynnikiem dopasowania o wartości $R^2 = 0,999989$ oraz najniższym średnim błędzie o wartości 1,2408 ps/nm. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele z kolejnych zestawów wraz ze wzrostem liczby epok obserwowano wzrost średniego błędu co może oznaczać przetrenowanie sieci.

W tabeli 5.10 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji OOK i opóźnienia 0,5 bit.

Tabela 5.10 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999970	0,999971	0,999974	0,999969	0,999969	0,999968	0,999969
śr. Błąd	2,029000	2,005700	1,794500	1,988500	2,027200	2,258600	2,104800
75, R^2	0,999973	0,999976	0,999976	0,999974	0,999971	0,999973	0,999975
śr. Błąd	1,788900	1,801600	1,691900	1,824200	1,939300	1,804400	1,919400
100, R^2	0,999978	0,999976	0,999977	0,999977	0,999975	0,999978	0,999977
śr. błąd	1,606900	1,616000	1,629800	1,667700	1,786300	1,641600	1,746000
150, R^2	0,999979	0,999978	0,999977	0,999978	0,999977	0,999979	0,999978
śr. błąd	1,575500	1,583100	1,619400	1,606800	1,689700	1,560700	1,646100
250, R^2	0,999980	0,999978	0,999978	0,999978	0,999974	0,999978	0,999978
śr. błąd	1,545500	1,740700	1,584000	1,618400	1,728200	1,685000	1,614200
350, R^2	0,999977	0,999976	0,999976	0,999977	0,999975	0,999978	0,999976
śr. błąd	1,622500	1,762200	1,689500	1,651000	1,723800	1,636800	1,687900
450, R^2	0,999973	0,999972	0,999973	0,999973	0,999965	0,999973	0,999974
śr. błąd	1,841000	1,871600	1,831000	1,843300	2,090900	1,889800	1,886100
550, R^2	0,998094	0,998572	0,998408	0,998646	0,998884	0,998932	0,998959
śr. błąd	22,676800	21,70230	18,435400	17,49740	19,19370	16,142076	16,751300
650, R^2	0,999976	0,999980	0,999979	0,999979	0,999977	0,999978	0,999973
śr. błąd	1,519500	1,461100	1,586700	1,500400	1,590600	1,633800	1,759500
750, R^2	0,999977	0,999977	0,999977	0,999980	0,999974	0,999975	0,999976
śr. błąd	1,550900	1,611100	1,573400	1,524800	1,632600	1,614000	1,735400
850, R^2	0,999974	0,999975	0,999976	0,999976	0,999976	0,999972	0,999971
śr. błąd	1,624800	1,684300	1,601500	1,676500	1,652400	1,743100	1,879700
950, R^2	0,999971	0,999975	0,999971	0,999975	0,999973	0,999968	0,999961
śr. błąd	1,827700	1,792000	1,861000	1,761200	1,785600	2,002200	2,154700
1000, R^2	0,999967	0,999970	0,999972	0,999970	0,999967	0,999959	0,999957
śr. Błąd	1,993500	1,979600	1,853800	2,115200	1,960300	2,197800	2,315600

Podsumowanie danych z tabeli 5.10:

Najlepsze wartości współczynników dopasowania poszczególnych zestawów uzyskano dla modeli sieci nauczonych dla 150, 250, 650 oraz 750 epok. Najniższe średnie wartości błędów

estymacji dyspersji chromatycznej uzyskano dla 5 z 7 modeli dla 650 i 750 epok. Jedną z najwyższych wartości dopasowania $R^2 = 0,999980$ oraz najniższą średnią wartość błędu 1,4611 ps/nm otrzymano dla zestawu nr 2 dla 650 epok. Po osiągnięciu przez poszczególne zestawy najniższych średnich wartości błędów, wraz ze wzrostem liczby epok zaobserwowano wzrost średniego błędu co może oznaczać przetrenowanie sieci.

W tabeli 5.11 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji DPSK i opóźnienia 0,5 bit.

Tabela 5.11 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia splotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999789	0,999778	0,999775	0,999776	0,999780	0,999761	0,999768
śr. błąd	0,079900	0,078100	0,080500	0,082600	0,079900	0,086800	0,090100
75, R^2	0,999799	0,999747	0,999804	0,999799	0,999809	0,999771	0,999777
śr. błąd	0,072300	0,080300	0,067600	0,074200	0,072900	0,087800	0,076800
100, R^2	0,999801	0,999798	0,999792	0,999823	0,999807	0,999815	0,999791
śr. błąd	0,069300	0,069700	0,069900	0,065400	0,071300	0,068200	0,072000
150, R^2	0,999805	0,999814	0,999819	0,999810	0,999812	0,999812	0,999809
śr. błąd	0,066400	0,063700	0,063300	0,067500	0,066000	0,066300	0,074500
250, R^2	0,999820	0,999813	0,999794	0,999819	0,999800	0,999817	0,999809
śr. błąd	0,064500	0,063700	0,063900	0,062900	0,066300	0,064000	0,064900
350, R^2	0,999815	0,999816	0,999813	0,999828	0,999818	0,999812	0,999799
śr. błąd	0,065400	0,064000	0,063200	0,060900	0,064900	0,065300	0,071400
450, R^2	0,999795	0,999787	0,999781	0,999804	0,999794	0,999808	0,999790
śr. błąd	0,070500	0,072400	0,072300	0,068200	0,069000	0,070700	0,073500
550, R^2	0,998033	0,998764	0,998109	0,998015	0,998287	0,998371	0,998481
śr. błąd	0,421400	0,289700	0,388800	0,376400	0,388900	0,368200	0,333500
650, R^2	0,999812	0,999805	0,999821	0,999804	0,999817	0,999825	0,999803
śr. błąd	0,062000	0,062000	0,060600	0,061100	0,061500	0,059300	0,064200
750, R^2	0,999805	0,999802	0,999806	0,999798	0,999793	0,999808	0,999801
śr. błąd	0,062300	0,065400	0,064300	0,064400	0,064600	0,062900	0,062700
850, R^2	0,999810	0,999798	0,999788	0,999804	0,999781	0,999799	0,999792
śr. błąd	0,064200	0,064600	0,065300	0,064600	0,068100	0,065100	0,068000
950, R^2	0,999797	0,999774	0,999770	0,999786	0,999790	0,999788	0,999797
śr. błąd	0,066300	0,072500	0,068800	0,066700	0,068900	0,067800	0,072500
1000, R^2	0,999774	0,999792	0,999789	0,999789	0,999753	0,999754	0,999758
śr. błąd	0,072600	0,072600	0,071700	0,071900	0,076000	0,074700	0,077100

Podsumowanie danych z tabeli 5.11:

Najlepsze wartości współczynników dopasowania modeli dla większości zestawów uzyskano dla niższej liczby epok (150 – 350). Dla 5 z 7 zestawów najniższe średnie wartości błędów

modeli otrzymano dla 650 epok. Jedną z najwyższych wartości współczynnika $R^2 = 0,999825$ oraz jednocześnie najniższy średni błąd estymacji 0,0593 dB uzyskano dla modelu z zestawu nr 6 dla 650 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średniej wartości błędu co może oznaczać przetrenowanie sieci.

W tabeli 5.12 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji OOK i opóźnienia 0,5 bit.

Tabela 5.12 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,986026	0,985134	0,985435	0,987946	0,986627	0,987249	0,986434
śr. błąd	0,311400	0,327000	0,320900	0,328900	0,327900	0,304800	0,331100
75, R^2	0,988279	0,985454	0,987483	0,986900	0,986797	0,986886	0,986365
śr. błąd	0,261500	0,297600	0,263000	0,276600	0,272600	0,308600	0,270500
100, R^2	0,987861	0,986697	0,986672	0,988141	0,987547	0,986534	0,987188
śr. błąd	0,271500	0,276000	0,253400	0,253400	0,256000	0,262600	0,265300
150, R^2	0,987273	0,987515	0,986267	0,988142	0,988148	0,986894	0,987547
śr. błąd	0,240200	0,235900	0,277100	0,254100	0,247500	0,252700	0,255100
250, R^2	0,988244	0,987674	0,986732	0,987703	0,988072	0,986164	0,987610
śr. błąd	0,234700	0,233900	0,247900	0,241600	0,233600	0,244600	0,240500
350, R^2	0,987394	0,987015	0,987210	0,987514	0,987393	0,986404	0,987377
śr. błąd	0,232500	0,234800	0,237600	0,240100	0,235500	0,244100	0,238900
450, R^2	0,987047	0,986746	0,986814	0,986935	0,987443	0,987581	0,987900
śr. błąd	0,238400	0,239800	0,241000	0,244400	0,243100	0,241700	0,235200
550, R^2	0,985957	0,986023	0,986131	0,986233	0,986905	0,985827	0,985425
śr. błąd	0,552500	0,517100	0,537500	0,488000	0,540800	0,504900	0,457100
650, R^2	0,986914	0,986585	0,986059	0,986835	0,987182	0,986624	0,987441
śr. błąd	0,235700	0,234200	0,243500	0,236600	0,236100	0,236200	0,229600
750, R^2	0,986544	0,986981	0,986738	0,987024	0,988605	0,986878	0,987843
śr. błąd	0,238200	0,232500	0,234500	0,236400	0,231300	0,235700	0,228200
850, R^2	0,987642	0,986753	0,987101	0,988068	0,987770	0,987080	0,986660
śr. błąd	0,231600	0,240900	0,231800	0,231000	0,232500	0,234200	0,243400
950, R^2	0,986770	0,985884	0,986829	0,986571	0,987514	0,987070	0,986414
śr. błąd	0,249000	0,247500	0,249700	0,245500	0,235400	0,235200	0,242400
1000, R^2	0,987859	0,987244	0,986446	0,986800	0,987670	0,987521	0,985023
śr. błąd	0,241900	0,242900	0,245000	0,241400	0,239600	0,241200	0,263900

Podsumowanie danych z tabeli 5.12:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano w większości przypadków dla niższej liczby epok. Najniższe średnie wartości błędów

estymacji przeniku otrzymano naprzemiennie dla modeli sieci nauczonych dla 750 oraz 850 epok. Najniższy średni błąd estymacji o wartości 0,2282 dB uzyskano dla modelu z zestawu nr 7 dla 750 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średniej wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.13 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji DPSK i opóźnienia 0,5 bit.

Tabela 5.13 Współczynniki dopasowania modeli R^2 oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia splotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,987499	0,989142	0,988896	0,988660	0,988341	0,987814	0,988236
śr. błąd	0,649600	0,588200	0,584700	0,620400	0,597500	0,625900	0,632500
75, R^2	0,989750	0,989311	0,989807	0,989117	0,989739	0,989883	0,988913
śr. błąd	0,553800	0,572100	0,545300	0,583000	0,560000	0,562000	0,593300
100, R^2	0,990533	0,990710	0,990386	0,990125	0,989935	0,988690	0,989971
śr. błąd	0,534800	0,528300	0,527500	0,541200	0,542500	0,571700	0,533100
150, R^2	0,990539	0,989439	0,989819	0,990438	0,989768	0,989620	0,990367
śr. błąd	0,527200	0,563700	0,533500	0,525100	0,533900	0,543500	0,522100
250, R^2	0,990231	0,989256	0,990239	0,990507	0,990493	0,989869	0,989796
śr. błąd	0,523800	0,541600	0,519400	0,510900	0,517000	0,534700	0,532700
350, R^2	0,989842	0,989986	0,990192	0,989834	0,990015	0,989621	0,989236
śr. błąd	0,532300	0,524100	0,520300	0,536900	0,525900	0,536300	0,542800
450, R^2	0,989438	0,989412	0,990003	0,989549	0,989698	0,989781	0,989342
śr. błąd	0,536900	0,536700	0,529500	0,536900	0,534800	0,539200	0,546000
550, R^2	0,986895	0,985382	0,987157	0,986185	0,985461	0,983110	0,987294
śr. błąd	0,784300	0,744400	0,758100	0,800900	0,821100	0,858400	0,722000
650, R^2	0,989114	0,989515	0,989677	0,990030	0,989520	0,989138	0,989163
śr. błąd	0,543200	0,533900	0,525800	0,522200	0,533200	0,539100	0,542400
750, R^2	0,989244	0,989318	0,989024	0,989249	0,989460	0,988781	0,988199
śr. błąd	0,534700	0,526500	0,540300	0,536000	0,534700	0,547700	0,559800
850, R^2	0,989260	0,988294	0,989246	0,988951	0,989468	0,988999	0,987901
śr. błąd	0,532600	0,555300	0,544100	0,541700	0,535200	0,543000	0,564000
950, R^2	0,989296	0,988469	0,988073	0,988837	0,989220	0,988287	0,987310
śr. błąd	0,536400	0,555100	0,559500	0,548800	0,538500	0,555600	0,582200
1000, R^2	0,988744	0,987766	0,988653	0,989122	0,988606	0,987847	0,987429
śr. błąd	0,559000	0,567700	0,555700	0,556300	0,557600	0,567600	0,573700

Podsumowanie danych z tabeli 5.13:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano w większości przypadków dla niższej liczby epok (100 – 250). Najwyższą wartość

dopasowania $R^2 = 0,990710$ otrzymano dla zestawu nr 2 dla 100 epok. Najniższe średnie wartości błędów estymacji OSNR dla większości zestawów (5 z 7) uzyskano dla 250 epok. Najniższy średni błąd estymacji o wartości 0,5109 dB uzyskano dla modelu z zestawu nr 4 dla 250 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średniej wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.14 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji OOK i opóźnienia 0,5 bit.

Tabela 5.14 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,992072	0,991813	0,991964	0,989481	0,992273	0,991041	0,990882
śr. błąd	0,468400	0,461000	0,470000	0,526700	0,445500	0,503900	0,507100
75, R^2	0,991862	0,992214	0,992447	0,992173	0,992293	0,991351	0,990810
śr. błąd	0,460200	0,438200	0,435900	0,440000	0,432000	0,459700	0,481400
100, R^2	0,991881	0,992046	0,992489	0,991823	0,992604	0,991259	0,992032
śr. błąd	0,442700	0,449400	0,440300	0,437300	0,429300	0,451400	0,436200
150, R^2	0,992696	0,991940	0,991965	0,992980	0,992749	0,992570	0,992423
śr. błąd	0,411100	0,428800	0,422500	0,401400	0,403400	0,415900	0,414100
250, R^2	0,992605	0,992654	0,992818	0,992260	0,992684	0,992187	0,992045
śr. błąd	0,406100	0,409300	0,400600	0,417000	0,403300	0,416100	0,419300
350, R^2	0,992395	0,991574	0,992539	0,992486	0,993025	0,992779	0,992436
śr. błąd	0,408100	0,414500	0,406500	0,406900	0,392800	0,402300	0,404400
450, R^2	0,992879	0,991705	0,992414	0,992264	0,992931	0,992297	0,992169
śr. błąd	0,392700	0,419800	0,405500	0,420000	0,395800	0,413900	0,420300
550, R^2	0,989515	0,988465	0,989306	0,989015	0,989772	0,989590	0,989500
śr. błąd	0,712400	0,657000	0,719700	0,736900	0,720900	0,651300	0,624200
650, R^2	0,992166	0,991928	0,992079	0,991895	0,992491	0,992062	0,991624
śr. błąd	0,398100	0,405700	0,400400	0,407300	0,396300	0,403200	0,408800
750, R^2	0,992164	0,991800	0,992121	0,991999	0,992473	0,992393	0,991397
śr. błąd	0,399600	0,406700	0,400900	0,405500	0,395600	0,399000	0,420600
850, R^2	0,992033	0,991599	0,991608	0,992524	0,991926	0,991570	0,990808
śr. błąd	0,407700	0,413700	0,414700	0,402100	0,411300	0,411900	0,437000
950, R^2	0,991990	0,991043	0,991790	0,992008	0,992189	0,991627	0,991448
śr. błąd	0,411900	0,434200	0,415200	0,412700	0,411100	0,416000	0,424900
1000, R^2	0,991970	0,991888	0,991394	0,991888	0,992073	0,992019	0,990666
śr. błąd	0,416600	0,416000	0,427400	0,423800	0,412300	0,409000	0,436100

Podsumowanie danych z tabeli 5.14:

Najlepsze wartości współczynników dopasowania modeli dla większości z poszczególnych zestawów uzyskano dla 250 oraz 350 epok. Najwyższy współczynnik dopasowania o wartości $R^2 = 0,993025$ otrzymano dla zestawu nr 5 dla 350 epok. Najniższe średnie wartości błędów dla badanych zestawów uzyskano dla różnej liczby epok. Najniższy średni błąd estymacji o wartości 0,3927 dB uzyskano dla modelu z zestawu nr 1 dla 450 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średniej wartości błędów co może oznaczać przetrenowanie sieci. W tabeli 5.15 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji DPSK i opóźnienia 1 bit.

Tabela 5.15 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia splotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999976	0,999981	0,999981	0,999980	0,999977	0,999978	0,999976
śr. błąd	2,144200	1,836700	1,722200	1,821000	1,993900	1,941400	2,090700
75, R^2	0,999982	0,999984	0,999985	0,999983	0,999979	0,999983	0,999983
śr. błąd	1,705500	1,587900	1,546400	1,647300	1,858200	1,676200	1,655000
100, R^2	0,999983	0,999985	<u>0,999986</u>	0,999985	0,999984	0,999985	0,999984
śr. błąd	1,652200	1,593700	1,503700	1,575300	1,606900	1,559000	1,797700
150, R^2	<u>0,999987</u>	<u>0,999987</u>	<u>0,999986</u>	<u>0,999986</u>	0,999984	<u>0,999987</u>	<u>0,999987</u>
śr. błąd	1,462400	1,421800	1,459900	1,465900	1,588600	1,447100	1,450800
250, R^2	0,999985	0,999986	<u>0,999986</u>	<u>0,999986</u>	0,999983	<u>0,999987</u>	0,999985
śr. błąd	1,529500	1,458900	1,502200	1,481600	1,620300	1,410000	1,555300
350, R^2	0,999984	0,999985	0,999984	0,999985	0,999984	0,999986	0,999985
śr. błąd	1,705600	1,588600	1,557100	1,487600	1,584300	1,532200	1,623700
450, R^2	0,999980	0,999979	0,999978	0,999981	0,999979	0,999983	0,999982
śr. błąd	1,757000	1,886400	2,019700	1,771800	1,847800	1,693000	1,833600
550, R^2	0,998160	0,998670	0,998559	0,998553	0,998813	0,998816	0,998859
śr. błąd	25,49800	20,52900	21,87600	20,75100	20,63300	18,75700	18,78200
650, R^2	0,999985	0,999986	<u>0,999986</u>	<u>0,999986</u>	<u>0,999985</u>	0,999985	0,999985
śr. błąd	1,451300	1,443400	1,431400	1,399200	1,462700	1,601200	1,500100
750, R^2	0,999985	0,999985	<u>0,999986</u>	<u>0,999986</u>	<u>0,999985</u>	0,999985	0,999981
śr. błąd	1,536600	1,479000	1,399700	1,440400	1,503400	1,516600	1,716500
850, R^2	0,999985	0,999984	0,999985	0,999984	0,999983	0,999985	0,999981
śr. błąd	1,441300	1,674000	1,518700	1,572900	1,593100	1,531500	1,742500
950, R^2	0,999981	0,999982	0,999981	0,999982	0,999981	0,999980	0,999975
śr. błąd	1,747900	1,759100	1,684800	1,732600	1,692900	1,864300	2,064000
1000, R^2	0,999978	0,999978	0,999975	0,999978	0,999977	0,999977	0,999977
śr. Błąd	1,848900	1,902100	2,093000	1,966300	2,035100	2,117900	2,039800

Podsumowanie danych z tabeli 5.15:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano w większości przypadków dla 150 epok. Takie same współczynniki dopasowania otrzymano dla zestawów 3, 4 i 5 dla 650 oraz 750 epok, jednak uzyskano przy tym niższe średnie wartości błędów estymacji dyspersji chromatycznej. Dla modelu z zestawu nr 4 uzyskano najniższy średni błąd o wartości 1,3992 ps/nm dla 650 epok. Po osiągnięciu najniższych wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.16 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska dyspersji chromatycznej dla modulacji OOK i opóźnienia 1 bit.

Tabela 5.16 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999964	0,999967	0,999967	0,999964	0,999960	0,999961	0,999962
śr. błąd	2,284800	2,324700	2,094200	2,302200	2,370700	2,342400	2,233200
75, R^2	0,999967	0,999972	0,999973	0,999971	0,999965	0,999963	0,999970
śr. błąd	2,113600	1,855900	1,909500	1,948400	2,1066	2,186600	2,073400
100, R^2	0,999969	0,999975	0,999974	0,999971	0,999968	0,999973	0,999972
śr. błąd	1,967400	1,763000	1,839700	1,909800	2,043600	1,866600	2,010100
150, R^2	0,999974	<u>0,999977</u>	0,999975	0,999974	0,999968	0,999976	0,999974
śr. błąd	1,832300	1,652800	1,762500	1,822700	2,108000	1,840600	1,761900
250, R^2	<u>0,999976</u>	0,999974	<u>0,999976</u>	<u>0,999977</u>	<u>0,999972</u>	<u>0,999977</u>	<u>0,999976</u>
śr. błąd	1,747600	1,702700	1,681600	1,662600	1,878200	1,736900	1,775700
350, R^2	0,999974	0,999971	0,999973	0,999975	0,999971	0,999974	0,999974
śr. błąd	1,795800	1,942000	1,804600	1,788500	1,942800	1,769400	1,987500
450, R^2	0,999968	0,999968	0,999967	0,999969	0,999969	0,999965	0,999965
śr. błąd	2,019000	2,133700	2,047300	2,045800	2,024200	2,172500	2,267300
550, R^2	0,998537	0,998089	0,998493	0,998542	0,998935	0,998814	0,998746
śr. błąd	22,11000	25,57200	23,11000	15,54500	19,57500	17,45300	19,39800
650, R^2	0,999973	<u>0,999977</u>	0,999973	0,999975	<u>0,999972</u>	0,999975	0,999974
śr. błąd	1,653800	1,644100	1,690200	1,607300	1,708400	1,655400	1,807100
750, R^2	0,999971	0,999972	0,999974	0,999973	0,999971	0,999972	0,999972
śr. błąd	1,743200	1,771900	1,698200	1,734000	1,786100	1,766000	1,797900
850, R^2	0,999972	0,999969	0,999972	0,999971	0,999966	0,999969	0,999969
śr. błąd	1,809400	1,859600	1,789500	1,834000	1,884400	1,862200	1,912200
950, R^2	0,999967	0,999970	0,999968	0,999968	0,999967	0,999969	0,999964
śr. błąd	1,965100	1,968200	1,967600	1,954300	1,961900	2,019700	2,152000
1000, R^2	0,999960	0,999967	0,999964	0,999964	0,999960	0,999964	0,999959
śr. błąd	2,142200	2,160600	2,164600	2,272800	2,252800	2,262400	2,430300

Podsumowanie danych z tabeli 5.16:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano w większości przypadków dla 250 epok. Najniższe średnie wartości błędów estymacji dla 5 z 7 zestawów uzyskano dla 650 epok. Dla modelu z zestawu nr 4 uzyskano najniższy średni błąd o wartości 1,6073 ps/nm dla 650 epok. Po osiągnięciu najniższych wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.17 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji DPSK i opóźnienia 1 bit.

Tabela 5.17 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,999696	0,999697	0,999701	0,999674	0,999675	0,999665	0,999702
śr. błąd	0,082700	0,088700	0,085200	0,090900	0,088400	0,093100	0,087900
75, R^2	0,999702	0,999721	0,999719	0,999723	0,999714	0,999733	0,999684
śr. błąd	0,077300	0,077000	0,076000	0,078100	0,080400	0,080500	0,095200
100, R^2	0,999735	0,999732	0,999701	0,999701	0,999717	0,999713	0,999722
śr. błąd	0,076300	0,077000	0,078000	0,077700	0,083400	0,083200	0,077100
150, R^2	0,999688	0,999717	0,999738	0,999725	0,999730	0,999731	0,999737
śr. błąd	0,082100	0,077200	0,069700	0,071400	0,073500	0,070800	0,075000
250, R^2	0,999716	0,999701	0,999724	0,999705	0,999711	0,999736	0,999668
śr. błąd	0,072900	0,073400	0,071600	0,071300	0,072200	0,068700	0,075100
350, R^2	0,999733	0,999718	0,999730	0,999714	0,999703	0,999733	0,999695
śr. błąd	0,070800	0,071600	0,070200	0,074500	0,074200	0,071200	0,075800
450, R^2	0,999709	0,999710	0,999693	0,999704	0,999733	0,999690	0,999709
śr. błąd	0,078400	0,077400	0,078800	0,074700	0,072800	0,078200	0,078800
550, R^2	0,998114	0,998455	0,998226	0,998182	0,998235	0,998409	0,997246
śr. błąd	0,398300	0,275700	0,404300	0,381600	0,368800	0,356000	0,453600
650, R^2	0,999720	0,999717	0,999713	0,999720	0,999703	0,999712	0,999730
śr. błąd	0,068000	0,069700	0,071300	0,070300	0,069900	0,070200	0,069100
750, R^2	0,999702	0,999697	0,999738	0,999754	0,999706	0,999736	0,999699
śr. błąd	0,070300	0,072800	0,067700	0,068800	0,071600	0,071800	0,075300
850, R^2	0,999705	0,999693	0,999708	0,999728	0,999695	0,999715	0,999694
śr. błąd	0,070700	0,073000	0,072500	0,072200	0,072900	0,070500	0,072900
950, R^2	0,999689	0,999707	0,999698	0,999692	0,999700	0,999704	0,999690
śr. błąd	0,074500	0,074800	0,076400	0,076400	0,073300	0,074400	0,076200
1000, R^2	0,999692	0,999679	0,999693	0,999696	0,999700	0,999672	0,999699
śr. błąd	0,078300	0,080400	0,078300	0,078600	0,077600	0,080100	0,079100

Podsumowanie danych z tabeli 5.17:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano dla różnej liczby epok. Najniższe średnie wartości błędów estymacji dla 6 z 7 zestawów uzyskano dla 650 i 750 epok. Dla modelu z zestawu nr 3 uzyskano najniższy średni błąd o wartości 0,0677 dB dla 750 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.18 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska przeniku dla modulacji OOK i opóźnienia 1 bit.

Tabela 5.18 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,987092	0,986244	0,987854	0,986110	0,985870	0,986220	0,986131
śr. błąd	0,293300	0,329900	0,306700	0,315900	0,307900	0,310100	0,412500
75, R^2	0,987405	0,986912	0,987797	0,987048	0,986802	0,986573	0,985480
śr. błąd	0,282800	0,278300	0,255400	0,296700	0,302800	0,352700	0,330700
100, R^2	0,987104	0,987132	0,987069	0,987281	0,987709	0,987760	0,987178
śr. błąd	0,262300	0,250400	0,246900	0,273700	0,269000	0,293200	0,269200
150, R^2	0,987029	0,987864	0,987046	0,987485	0,988104	0,987219	0,985771
śr. błąd	0,255500	0,239700	0,240900	0,242600	0,249000	0,248000	0,278600
250, R^2	0,987809	0,987403	0,986950	0,987315	0,987476	0,987599	0,987306
śr. błąd	0,233300	0,241300	0,246800	0,239500	0,240700	0,240600	0,236800
350, R^2	0,987832	0,987259	0,987435	0,987747	0,988164	0,987635	0,987845
śr. błąd	0,231100	0,240900	0,236600	0,236900	0,235500	0,242100	0,243100
450, R^2	0,987338	0,987765	0,986976	0,987709	0,988497	0,986910	0,987957
śr. błąd	0,242300	0,241300	0,241800	0,241100	0,234100	0,253100	0,242000
550, R^2	0,986503	0,986174	0,985345	0,986138	0,987226	0,986759	0,986671
śr. błąd	0,561800	0,531600	0,560400	0,548500	0,538300	0,551600	0,500500
650, R^2	0,987461	0,987128	0,987943	0,987150	0,987018	0,988102	0,987138
śr. błąd	0,233400	0,232800	0,230000	0,231800	0,237000	0,228100	0,268300
750, R^2	0,987465	0,987435	0,987733	0,987341	0,987680	0,987802	0,987911
śr. błąd	0,238700	0,255100	0,236200	0,234600	0,236600	0,233900	0,230000
850, R^2	0,987973	0,987381	0,987285	0,986910	0,987342	0,987128	0,988142
śr. błąd	0,236900	0,243300	0,235300	0,241200	0,237300	0,241600	0,231300
950, R^2	0,987624	0,987034	0,987168	0,986899	0,987886	0,987813	0,987462
śr. błąd	0,235700	0,258100	0,234300	0,244000	0,238000	0,236600	0,237800
1000, R^2	0,987528	0,987543	0,987788	0,987767	0,987713	0,988129	0,987692
śr. błąd	0,244100	0,242000	0,242900	0,238300	0,247100	0,237000	0,243300

Podsumowanie danych z tabeli 5.18:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano dla różnej liczby epok. Najniższe średnie wartości błędów estymacji otrzymano dla 650 epok. Dla modelu z zestawu nr 6 dla 650 epok uzyskano najniższy średni błąd o wartości 0,2281 dB. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.19 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji DPSK i opóźnienia 1 bit.

Tabela 5.19 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia splotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,987746	0,987359	0,985443	0,987732	0,987596	0,985479	0,985638
śr. błąd	0,644700	0,619700	0,711500	0,638600	0,646300	0,705800	0,688500
75, R^2	0,988146	0,987071	0,988519	0,987403	0,988610	0,987415	0,987236
śr. błąd	0,644700	0,622000	0,581300	0,616100	0,603900	0,610200	0,618000
100, R^2	0,987985	0,988545	0,988463	0,988148	0,989123	0,988446	0,988278
śr. błąd	0,589400	0,562700	0,573200	0,595900	0,569100	0,572500	0,598600
150, R^2	0,989075	0,988603	0,989009	0,989091	0,989179	0,987744	0,988755
śr. błąd	0,559000	0,577000	0,551500	0,559200	0,560400	0,600300	0,583900
250, R^2	0,989085	0,988597	0,989035	0,989277	0,989077	0,989176	0,988529
śr. błąd	0,550800	0,562700	0,558500	0,555600	0,553400	0,543500	0,563700
350, R^2	0,989184	0,989022	0,988867	0,988741	0,988630	0,987998	0,987503
śr. błąd	0,551800	0,549800	0,555500	0,554200	0,563700	0,574800	0,599900
450, R^2	0,988820	0,988683	0,988362	0,988620	0,989434	0,988008	0,987881
śr. błąd	0,561100	0,558900	0,569600	0,560100	0,543400	0,583500	0,583500
550, R^2	0,985271	0,985434	0,984299	0,984970	0,985412	0,985262	0,984245
śr. błąd	0,809600	0,777700	0,838100	0,821000	0,844800	0,807700	0,770600
650, R^2	0,987984	0,987576	0,987914	0,988329	0,988243	0,988557	0,986759
śr. błąd	0,575300	0,573600	0,565100	0,561800	0,566200	0,553000	0,600100
750, R^2	0,988343	0,987797	0,988125	0,988593	0,988546	0,988126	0,986914
śr. błąd	0,563400	0,578800	0,563700	0,557900	0,557800	0,565500	0,590600
850, R^2	0,988451	0,987719	0,987564	0,987136	0,988102	0,986895	0,987276
śr. błąd	0,558700	0,581400	0,580900	0,590700	0,565500	0,587800	0,586400
950, R^2	0,987990	0,986664	0,987348	0,988232	0,988060	0,987488	0,986637
śr. błąd	0,581700	0,597800	0,580600	0,570700	0,569400	0,576600	0,596300
1000, R^2	0,987383	0,986712	0,986981	0,988041	0,987414	0,987996	0,986857
śr. błąd	0,586900	0,595800	0,599700	0,581700	0,586700	0,577400	0,600600

Podsumowanie danych z tabeli 5.19:

Najlepsze wartości współczynników dopasowania modeli oraz najniższe średnie wartości błędów dla poszczególnych zestawów uzyskano w większości przypadków dla 250 oraz 350 epok. Dla modelu z zestawu nr 5 uzyskano w ujęciu ogólnym najniższy średni błąd o wartości 0,5434 dB dla 450 epok. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

W tabeli 5.20 zamieszczono parametry opisujące modele uzyskane w procesie uczenia sieci dla zjawiska szumu ASE dla modulacji OOK i opóźnienia 1 bit.

Tabela 5.20 Współczynniki dopasowania modeli R^2 oraz średnie wartości błęd wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.

Liczba epok, R^2 błąd średni	Numer zestawu						
	1	2	3	4	5	6	7
	Liczba węzłów w warstwach w pełni połączonych						
	384/128	512/256	512/128	384/256	384/64	384/384	512/512
50, R^2	0,988658	0,988943	0,989100	0,987427	0,989227	0,989251	0,989198
śr. błąd	0,613900	0,579800	0,566800	0,609900	0,589600	0,578000	0,605300
75, R^2	0,990128	0,990774	0,989784	0,989210	0,990386	0,988959	0,988578
śr. błąd	0,522400	0,523200	0,528000	0,549000	0,518100	0,537500	0,553300
100, R^2	0,990713	0,989615	0,990583	0,989904	0,990733	0,989892	0,989654
śr. błąd	0,500500	0,533500	0,479800	0,526400	0,496900	0,511400	0,515400
150, R^2	0,990689	0,990363	0,990438	0,990779	0,990569	0,990075	0,988979
śr. błąd	0,475500	0,490900	0,479700	0,477300	0,487300	0,497200	0,511500
250, R^2	0,990758	0,990934	0,990715	0,990565	0,990784	0,990596	0,990731
śr. błąd	0,470000	0,475900	0,474100	0,480900	0,478300	0,481400	0,475700
350, R^2	0,990787	0,990559	0,990038	0,989993	0,990195	0,990312	0,990359
śr. błąd	0,478800	0,471400	0,490200	0,488000	0,483100	0,482200	0,485800
450, R^2	0,990404	0,989305	0,989653	0,990201	0,989695	0,989842	0,989205
śr. błąd	0,483000	0,500200	0,493000	0,488100	0,500400	0,498400	0,502700
550, R^2	0,987923	0,987304	0,987341	0,988179	0,986587	0,986505	0,986660
śr. błąd	0,761900	0,687000	0,7780	0,693200	0,790900	0,749800	0,702200
650, R^2	0,990773	0,989704	0,989306	0,990135	0,990006	0,989800	0,988974
śr. błąd	0,462500	0,483800	0,489000	0,472300	0,4737	0,483500	0,495700
750, R^2	0,989753	0,989654	0,989110	0,988798	0,990116	0,989669	0,988974
śr. błąd	0,481400	0,488400	0,494100	0,498200	0,474400	0,486000	0,495500
850, R^2	0,989790	0,989479	0,990044	0,990177	0,990004	0,990022	0,988950
śr. błąd	0,477600	0,483300	0,474400	0,479200	0,476700	0,484900	0,499400
950, R^2	0,989530	0,989353	0,989391	0,989176	0,989948	0,988998	0,988760
śr. błąd	0,489700	0,487400	0,484800	0,498500	0,478100	0,499900	0,502200
1000, R^2	0,989940	0,988122	0,988985	0,989656	0,990118	0,989151	0,988137
śr. błąd	0,482700	0,521000	0,495500	0,500200	0,479900	0,499600	0,526800

Podsumowanie danych z tabeli 5.20:

Najlepsze wartości współczynników dopasowania modeli dla poszczególnych zestawów uzyskano w większości przypadków dla 250 epok. Najniższe średnie wartości błędów estymacji otrzymano dla 250 oraz 650 epok. Dla modelu z zestawu nr 1 uzyskano najniższy średni błąd estymacji o wartości 0,4625 dB. Po osiągnięciu najniższych średnich wartości błędów przez poszczególne modele wraz ze wzrostem liczby epok zaobserwowano wzrost średnich wartości błędów co może oznaczać przetrenowanie sieci.

5.4 Podsumowanie wyników uczenia sieci spłotowej

Podstawowym parametrem informującym o jakości gotowego modelu jest współczynnik dopasowania R^2 . Dla przeprowadzonych badań dla poszczególnych grup opóźnień bitowych i modulacji uzyskano w wielu przypadkach takie same wartości R^2 . Aby wskazać najlepszy model dla danej grupy należało dodatkowo porównać średnie wartości błędów modeli. Należy jednak pamiętać, że średni błąd nie zawsze jest tożsamy z najwyższym współczynnikiem dopasowania modelu. Oznacza to, że model z najwyższym współczynnikiem dopasowania nie musi charakteryzować się najniższym średnim błędem dla danego zjawiska, oraz nie musi odzwierciedlać sieci nauczonej najlepiej. W tabelach 5.21 - 5.23 zamieszczono średnie wartości błędów wyznaczanych parametrów dla najwyższych współczynników R^2 oraz współczynniki R^2 dla najmniejszych średnich wartości błędów uzyskane dla poszczególnych zjawisk w procesie uczenia sieci spłotowej.

Tabela 5.21 Podsumowanie najniższych średnich wartości błędów dyspersji chromatycznej oraz współczynników dopasowania R^2 uzyskanych w procesie uczenia sieci; CD – dyspersja chromatyczna.

Opóźnienie bitowe	Modulacja	Średni błąd CD / R^2	Liczba epok	Numer zestawu
średnie wartości błędów dyspersji chromatycznej dla najwyższych współczynników R^2				
0,25	DPSK	1,3155 / 0,999988	650	1
	OOK	1,6099 / 0,999976		4
0,5	DPSK	1,2408 / 0,999989		1
	OOK	1,4611 / 0,999980		2
1	DPSK	1,4100 / 0,999987	250	6
	OOK	1,6441 / 0,999977	650	2
współczynniki R^2 dla najmniejszych średnich wartości błędów dyspersji chromatycznej				
0,25	DPSK	1,3155 / 0,999988	650	1
	OOK	1,6099 / 0,999976		4
0,5	DPSK	1,2408 / 0,999989		1
	OOK	1,4611 / 0,999980		2
1	DPSK	1,3992 / 0,999986		4
	OOK	1,6073 / 0,999975		4

Tabela 5.22 Podsumowanie najniższych średnich wartości błędów przeniku oraz współczynników dopasowania R^2 uzyskanych w procesie uczenia sieci.

Opóźnienie bitowe	Modulacja	Średni błąd przeniku / R^2	Liczba epok	Numer zestawu
średnie wartości błędów przeniku dla najwyższych współczynników R^2				
0,25	DPSK	0,0858 / 0,999588	250	1
	OOK	0,2651 / 0,986430	250	5
0,5	DPSK	0,0609 / 0,999828	350	4
	OOK	0,2313 / 0,988605	750	5
1	DPSK	0,0688 / 0,999754	750	4
	OOK	0,2341 / 0,988497	450	5
współczynniki R^2 dla najmniejszych średnich wartości błędów przeniku				
0,25	DPSK	0,0808 / 0,999537	650	7
	OOK	0,2549 / 0,985635		1
0,5	DPSK	0,0593 / 0,999825	750	6
	OOK	0,2282 / 0,987843		7
1	DPSK	0,0677 / 0,999738	650	3
	OOK	0,2281 / 0,988102	650	6

Tabela 5.23 Podsumowanie najniższych średnich wartości błędów OSNR oraz współczynników dopasowania R^2 uzyskanych w procesie uczenia sieci; OSNR – Optyczny stosunek sygnał-szum.

Opóźnienie bitowe	Modulacja	Średni błąd OSNR / R^2	Liczba epok	Numer zestawu
średnie wartości błędów OSNR dla najwyższych współczynników R^2				
0,25	DPSK	0,6607 / 0,984936	650	5
	OOK	0,4832 / 0,989758	650	1
0,5	DPSK	0,5283 / 0,990710	100	2
	OOK	0,3928 / 0,993025	350	5
1	DPSK	0,5434 / 0,989434	450	5
	OOK	0,4759 / 0,990934	250	2
współczynniki R^2 dla najmniejszych średnich wartości błędów OSNR				
0,25	DPSK	0,6607 / 0,984936	650	5
	OOK	0,4803 / 0,989493	850	1, 5
0,5	DPSK	0,5109 / 0,990507	250	4
	OOK	0,3927 / 0,992879	450	1
1	DPSK	0,5434 / 0,989434		450
	OOK	0,4625 / 0,990773	650	1

Na podstawie analizy danych zawartych w powyższych tabelach (5.21 – 5.23) oraz uwzględniając wyniki przedstawione w tabelach 5.3 – 5.20 ustalono następujące wnioski:

a) dla dyspersji chromatycznej

- dla opóźnień bitowych 0,25 oraz 0,5 dla obu badanych modulacji, dla najwyższych współczynników R^2 uzyskano najniższe średnie wartości błędów. Dla opóźnienia 1 bit dla modeli z najwyższymi współczynnikami dopasowania uzyskano gorsze średnie wartości błędów niż dla modeli z niższymi współczynnikami R^2 . Najlepsze rezultaty uczenia sieci dla większości modeli dyspersji chromatycznej uzyskano dla 650 epok.

- dla modulacji DPSK dla wszystkich opóźnień bitowych uzyskano lepsze średnie wartości błędów oraz współczynniki dopasowania w porównaniu do modulacji OOK,
- dla obu badanych modulacji najlepsze wyniki uczenia uzyskano dla opóźnienia bitowego 0,5.
- dla modulacji DPSK największy średni błąd uzyskano dla opóźnienia 1 bit, natomiast dla modulacji OOK dla opóźnienia 0,25 bit.

b) dla zjawiska przeniku

- najwyższe współczynniki dopasowania dla 4 z 6 przypadków uzyskano dla niższej liczby epok. W żadnym przypadku dla najwyższych współczynników R^2 nie uzyskano najniższej średniej wartości błędu. Dla wszystkich przypadków, najniższe średnie wartości błędów uzyskano dla większej liczby epok.
- dla wszystkich opóźnień bitowych najwyższe współczynniki dopasowania uzyskano dla modulacji DPSK.
- najniższe średnie wartości błędów uzyskano dla opóźnienia 0,5 bit dla modulacji DPSK.
- najwyższe średnie wartości błędów uzyskano dla obu modulacji dla opóźnienia 0,25 bit.

c) dla zjawiska szumu ASE

- dla opóźnień 0,5 oraz 1 bit najwyższe współczynniki dopasowania uzyskano w większości przypadków dla niższej liczby epok (do 650). Dla opóźnienia 0,25 bit najwyższe współczynniki R^2 uzyskano dla 650 epok. Dla 3 z 6 najniższych średnich wartości błędów OSNR uzyskano dla modeli z większą liczbą epok.
- dla opóźnienia 0,5 bit dla obu modulacji uzyskano najwyższe współczynniki R^2 oraz najniższe średnie wartości błędów OSNR względem innych opóźnień bitowych.
- najwyższe współczynniki dopasowania modeli oraz najniższe średnie wartości błędów OSNR dla wszystkich opóźnień bitowych uzyskano dla modulacji OOK, względem modulacji DPSK.
- najwyższy błąd średni OSNR uzyskano dla obu modulacji dla opóźnienia 0,25 bit.

d) wnioski ogólne:

- dla połowy modeli z tabel 5.21 - 5.23 najwyższy współczynnik dopasowania R^2 uzyskano dla niższej liczby epok.
- dla 15 z 18 modeli najniższą średnią wartość błędu uzyskano dla wyższej liczby epok. Dla 12 modeli była to wartość 650 epok.
- dla wszystkich badanych zjawisk i modulacji najwyższe współczynniki dopasowania modeli oraz najniższe średnie wartości błędów uzyskano dla opóźnienia 0,5 bit.

- w przypadku sieci uczonych dla modulacji DPSK, uzyskiwano niższy błąd uczenia dla zjawisk dyspersji chromatycznej i przeniku względem modulacji OOK. W przypadku sieci uczonych dla modulacji OOK, uzyskiwano niższy błąd uczenia dla zjawiska szumu ASE względem modulacji DPSK,
- dla 1/3 wszystkich wybranych modeli najlepsze jakościowo parametry uczenia uzyskano dla zestawu nr 1.
- dla większości zestawów po uzyskaniu przez dany model najniższej średniej wartości błędu wraz ze wzrostem liczby epok w kolejnych badanych próbach następował wyraźny wzrost wartości tego błędu. Taki scenariusz może oznaczać przetrenowanie sieci. Oceniając jakość uzyskanych modeli na podstawie średnich wartości błędów można uznać, że dla wielu zbadanych przypadków liczba epok 650, jest optymalnym parametrem dla przeprowadzonego procesu uczenia.

W modelach sieci nauczonych dla 550 epok zaobserwowano wyraźny wzrost średnich wartości błędów estymacji. Trudno jest wskazać przyczynę tak uzyskanych wyników, jednak jest to sytuacja powtarzalna dla całego zakresu badań wykonywanych dla 550 epok. Ze względu na wysoki błąd, modele te nie zostały uwzględnione w przeprowadzonej analizie. Nie zostały również wykorzystane w procesie wyznaczania wartości, który został omówiony w rozdziale nr 6.

6. Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska

Końcowym etapem prowadzonych badań była weryfikacja gotowych modeli uzyskanych w procesie uczenia sieci oraz ich wykorzystanie w wyznaczaniu wartości parametrów opisujących równocześnie występujące zjawiska. Proces ten przeprowadzono na dodatkowych zestawach danych. Każdy zestaw zbudowany był z 3000 portretów fazy. Wszystkie obrazy były równocześnie zakłócone kombinacją zjawisk dyspersji chromatycznej w zakresie 200 – 1800 ps/nm oraz przeniku i szumu ASE (wyrażonym parametrem OSNR) oba w zakresie 5 – 40 dB. W procesie wyznaczania wartości wykorzystano wszystkie modele, które omówiono w poprzednim rozdziale.

W tabelach 6.1 - 6.12 przedstawiono wyniki uzyskane w procesie wyznaczania wartości parametrów równocześnie występujących zjawisk dyspersji chromatycznej, przeniku oraz szumu ASE i odpowiadające im portrety fazy. Wartości zamieszczone w tabelach 6.1, 6.3, 6.5, 6.7, 6.9 i 6.11 wyrażone są w procentach i oznaczają liczbę przypadków względem całego zestawu danych (3000), w których różnica między wartością zadaną i otrzymaną mieściła się w granicach poniżej 2% wartości zadanej dla dyspersji chromatycznej oraz poniżej 0,5 [dB] dla przeniku i OSNR (wymagania stawiane technikom monitorowania, tabela 2.1). **Na przykład** wartość 99,63 oznacza, że spośród 3000 badanych portretów fazy, dla 2989 została poprawnie określona wartość mierzonego zjawiska z dopuszczalnym błędem. Wartości zapisane procentowo, zostały zaokrąglono do 2 miejsc po przecinku co w części przypadków może powodować utratę precyzji, dlatego w przypadku przeliczania wartości procentowej na liczbę obrazów, otrzymany wynik należy zaokrąglić do najbliższej liczby całkowitej. Jeśli chodzi o numery zestawów (od 1 do 7) należy pamiętać, że oznaczają one liczbę węzłów w warstwach w pełni połączonych. Na przykład dla zestawu numer 1 jest to 384/128 tzn. 384 węzły w warstwie pierwszej i 128 w drugiej. W przypadku tabel 6.2, 6.4, 6.6, 6.8, 6.10 i 6.12 zawierających portrety fazy wartości znajdujące się w kolumnie „Zadana” oznaczają wartość referencyjną danego zjawiska, natomiast w kolumnie „Uzyskana” oznaczają wartości otrzymane w procesie wyznaczania wartości po zastosowaniu uzyskanych modeli. Wyniki badań przedstawiające rezultaty wykorzystania modeli do wyznaczania wartości liczbowych parametrów opisujących monitorowane zjawiska zamieszczono według następującej kolejności: modulacja DPSK i OOK, opóźnienie 0,25 bit, przepływność 10 Gbit/s; modulacja

DPSK i OOK, opóźnienie 0,5 bit, przepływność 10 Gbit/s; modulacja DPSK i OOK, opóźnienie 1 bit, przepływność 10 Gbit/s.

























W tab. 6.1 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,25 bit.

Tabela 6.1 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,25 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

Zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	99,63	99,30	99,57	99,27	99,37	99,33	99,30
przenik		99,10	99,10	98,80	99,13	99,33	99,13	98,90
OSNR		71,50	70,23	70,80	72,10	71,50	71,10	68,20
CD	75	99,53	99,33	99,60	99,60	99,43	99,60	99,53
przenik		99,60	99,60	99,60	99,50	99,63	99,70	99,50
OSNR		74,50	77,90	79,50	74,83	77,30	75,50	74,20
CD	100	99,50	99,60	99,70	99,70	99,67	99,60	99,60
przenik		99,60	99,53	99,63	99,60	99,63	99,50	99,53
OSNR		81,60	83,40	82,20	81,60	83,20	76,73	83,60
CD	150	99,70	99,63	99,83	99,67	99,63	99,57	99,60
przenik		99,63	99,60	99,63	99,50	99,70	99,73	99,63
OSNR		85,83	89,23	87,50	88,70	88,60	86,80	86,50
CD	250	99,60	99,67	99,77	99,70	99,60	99,60	99,60
przenik		99,60	99,70	99,70	99,83	99,60	99,63	99,63
OSNR		91,60	92,63	92,60	91,33	93,00	89,50	92,13
CD	350	99,43	99,37	99,47	99,67	99,37	99,47	99,47
przenik		99,60	99,70	99,70	99,83	99,60	99,63	99,63
OSNR		91,60	92,63	92,60	91,33	93,00	89,50	92,13
CD	450	99,50	99,37	99,53	99,37	99,17	99,63	99,33
przenik		99,50	99,60	99,53	99,50	99,60	99,60	99,70
OSNR		92,03	91,63	93,50	93,73	93,30	92,70	92,80
CD	650	99,67	99,60	99,60	99,73	99,73	99,63	99,60
przenik		99,60	99,80	99,70	99,70	99,60	99,70	99,50
OSNR		94,50	94,80	94,33	94,10	95,03	94,80	94,83
CD	750	99,60	99,50	99,63	99,63	99,63	99,73	99,53
przenik		99,70	99,80	99,70	99,63	99,70	99,60	99,63
OSNR		94,50	94,10	94,70	94,70	94,70	94,30	94,80
CD	850	99,63	99,53	99,43	99,70	99,57	99,27	99,37
przenik		99,63	99,63	99,73	99,73	99,63	99,70	99,80
OSNR		94,13	94,60	94,50	94,83	94,63	94,40	94,70
CD	950	99,20	99,70	98,77	99,70	99,37	99,33	99,37
przenik		99,63	99,60	99,70	99,70	99,73	99,60	99,60
OSNR		94,30	94,40	94,23	94,53	94,40	94,53	93,80
CD	1000	99,43	99,43	99,27	99,20	99,50	99,07	99,17
przenik		99,63	99,60	99,70	99,60	99,73	99,53	99,63
OSNR		94,40	93,30	94,60	94,30	93,90	94,10	94,03

W tab. 6.2 przedstawiono wybrane portrety fazy dla modulacji DPSK i opóźnienia 0,25 bit.

Tabela 6.2 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 0,25 bitu.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	575,393	573,901	1181,251	1180,866	1526,577	1526,490	474,841	475,371
Przenik [dB]	27,661	27,606	27,328	27,114	17,905	17,935	13,424	13,425
OSNR [dB]	13,669	13,697	28,136	28,019	12,477	12,467	10,995	11,000
Portret fazy								
CD [ps/nm]	1348,937	1347,536	403,874	410,7718	498,336	495,952	1476,264	1478,038
Przenik [dB]	10,152	10,100	12,370	12,304	25,315	25,249	9,205	9,154
OSNR [dB]	24,565	24,872	27,258	27,187	27,927	27,929	36,758	36,694
Portret fazy								
CD [ps/nm]	1561,776	1563,929	1095,913	1095,169	1257,971	1260,444	1386,480	1381,924
Przenik [dB]	9,375	9,442	12,285	12,294	26,397	26,322	15,484	15,552
OSNR [dB]	31,014	30,921	27,885	27,714	35,637	35,482	25,706	25,733
Portret fazy								
CD [ps/nm]	1530,788	1533,442	895,080	895,439	1193,366	1192,037	1356,869	1356,617
Przenik [dB]	29,089	29,079	17,794	17,764	29,210	29,195	18,875	18,876
OSNR [dB]	12,449	12,699	10,965	10,958	29,792	29,637	17,446	17,410
Portret fazy								
CD [ps/nm]	1045,300	1045,982	752,575	755,681	472,840	472,474	1151,505	1152,780
Przenik [dB]	29,209	29,207	16,300	16,323	11,334	11,331	11,972	11,942
OSNR [dB]	16,771	16,629	23,215	23,275	13,851	14,023	16,706	16,628
Portret fazy								
CD [ps/nm]	1270,476	1268,868	944,957	944,560	400,326	400,427	1186,926	1185,018
Przenik [dB]	8,286	8,245	13,062	13,051	6,217	6,229	26,512	26,476
OSNR [dB]	14,514	14,439	21,827	21,701	11,307	11,222	16,224	16,099

























W tab. 6.3 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,25 bit.

Tabela 6.3 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,25 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

R ² dla zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	97,97	95,83	97,33	98,17	96,53	95,27	96,53
przenik		90,10	88,90	88,60	90,30	89,90	87,23	89,83
OSNR		74,50	81,23	78,10	71,10	77,50	78,83	79,20
CD	75	97,77	97,13	98,50	97,27	97,50	98,07	97,70
przenik		94,50	95,13	92,73	93,40	94,70	93,10	90,53
OSNR		83,00	88,00	88,70	76,90	86,40	87,00	87,00
CD	100	97,37	97,50	97,57	97,37	96,77	97,57	98,43
przenik		95,73	95,90	96,00	94,60	96,23	96,10	96,00
OSNR		85,90	87,50	89,40	87,70	90,10	84,83	89,80
CD	150	97,47	98,47	98,40	97,90	96,77	98,17	98,17
przenik		96,83	96,83	96,80	96,30	96,40	96,70	97,13
OSNR		92,73	92,23	92,50	92,73	91,20	89,30	91,00
CD	250	98,13	98,90	98,47	97,90	97,47	98,13	98,07
przenik		96,83	96,73	96,80	96,90	96,83	96,60	96,90
OSNR		94,60	94,60	93,80	93,23	94,40	94,20	93,83
CD	350	97,97	98,13	97,80	98,00	97,80	97,63	97,53
przenik		96,90	96,80	97,13	96,70	97,00	96,53	97,00
OSNR		94,70	94,53	94,10	94,70	94,20	92,83	93,40
CD	450	97,70	97,77	96,97	97,40	97,03	97,30	97,67
przenik		95,63	96,70	96,70	96,80	97,00	97,00	96,90
OSNR		94,50	93,43	93,33	94,40	94,00	94,80	91,70
CD	650	97,90	98,00	98,17	98,07	98,00	98,33	98,37
przenik		96,90	96,83	96,83	96,90	96,60	97,30	97,00
OSNR		95,20	95,40	95,70	95,00	95,03	95,53	94,83
CD	750	98,27	98,13	98,33	97,80	98,10	97,87	97,80
przenik		96,80	96,80	96,93	96,63	96,90	97,13	96,50
OSNR		95,40	95,30	94,93	95,40	95,10	95,30	95,43
CD	850	97,87	97,93	96,47	98,50	98,17	98,37	97,80
przenik		97,30	97,03	97,00	96,80	97,60	97,03	96,90
OSNR		95,00	95,90	95,13	95,23	95,30	95,03	94,90
CD	950	98,27	96,80	97,63	98,20	98,00	97,43	96,97
przenik		97,03	96,90	97,10	96,80	96,70	96,70	96,90
OSNR		94,93	95,10	95,33	95,53	95,13	95,30	95,30
CD	1000	97,53	97,30	97,10	97,93	97,43	97,83	97,93
przenik		97,10	96,33	96,80	96,50	96,70	97,20	96,73
OSNR		95,13	95,30	95,33	94,93	95,20	94,33	94,83

W tab. 6.4 przedstawiono wybrane portrety fazy dla modulacji OOK i opóźnienia 0,25 bit.

Tabela 6.4 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnienia 0,25 bit.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	478,560	478,982	441,931	443,390	1039,084	1039,328	1585,608	1587,727
Przenik [dB]	19,550	19,501	10,868	10,794	33,621	33,577	11,668	11,600
OSNR [dB]	25,626	25,444	20,565	20,632	8,830	8,743	11,741	11,878
Portret fazy								
CD [ps/nm]	978,217	979,463	1239,028	1238,642	708,250	705,609	1479,782	1480,198
Przenik [dB]	14,892	14,861	18,756	18,702	17,227	17,181	5,724	5,653
OSNR [dB]	21,092	21,073	16,688	16,694	15,926	15,865	29,620	29,671
Portret fazy								
CD [ps/nm]	1508,333	1511,575	471,894	470,984	1266,907	1266,913	1569,461	1570,927
Przenik [dB]	20,516	20,513	39,944	39,892	33,674	33,722	15,371	15,362
OSNR [dB]	14,238	14,203	28,980	28,982	25,710	25,729	20,009	19,944
Portret fazy								
CD [ps/nm]	554,784	555,321	604,365	603,486	1080,304	1081,018	1004,575	1006,865
Przenik [dB]	16,490	16,46	29,388	29,391	28,226	28,145	5,816	5,759
OSNR [dB]	16,803	16,809	29,516	29,36	13,976	13,933	9,245	9,263
Portret fazy								
CD [ps/nm]	717,653	719,073	1328,916	1327,540	1286,947	1288,889	561,301	562,062
Przenik [dB]	31,764	31,746	27,695	27,657	6,406	6,349	24,521	24,478
OSNR [dB]	5,268	5,247	11,606	11,750	20,104	20,099	12,086	12,018
Portret fazy								
CD [ps/nm]	759,858	757,800	1080,042	1079,887	1300,229	1301,152	562,190	563,168
Przenik [dB]	11,937	11,901	18,241	18,219	12,907	12,909	27,625	27,588
OSNR [dB]	22,995	23,010	21,108	21,149	28,186	28,152	16,044	16,043

























W tab. 6.5 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,5 bit.

Tabela 6.5 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,5 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

R ² dla zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	99,20	99,60	99,63	99,50	99,27	99,20	99,47
przenik		99,80	99,73	99,60	99,70	99,70	99,63	99,80
OSNR		72,53	76,83	80,13	77,00	75,33	78,80	76,00
CD	75	99,47	99,43	99,67	99,47	99,30	99,30	99,60
przenik		99,80	99,40	99,63	99,80	99,80	99,70	99,63
OSNR		85,90	80,40	87,20	81,90	81,50	85,53	85,60
CD	100	99,53	99,73	99,60	99,60	99,33	99,67	99,43
przenik		99,90	99,90	99,80	99,80	99,80	99,80	99,80
OSNR		87,20	88,30	89,33	85,30	88,20	89,33	89,30
CD	150	99,63	99,73	99,67	99,80	99,47	99,60	99,60
przenik		99,90	99,93	99,80	99,80	99,70	99,90	99,90
OSNR		92,70	92,53	92,00	92,10	90,20	91,43	92,00
CD	250	99,63	99,77	99,70	99,60	99,40	99,77	99,77
przenik		99,83	99,90	99,73	99,90	99,80	99,83	99,80
OSNR		93,93	94,10	94,30	93,80	93,43	93,70	94,00
CD	350	99,67	99,67	99,63	99,70	99,50	99,53	99,60
przenik		99,73	99,73	99,73	99,80	99,80	99,83	99,80
OSNR		94,93	94,90	94,20	94,20	94,23	94,73	94,90
CD	450	99,30	99,30	99,60	99,30	99,30	99,20	99,57
przenik		99,70	99,73	99,80	99,80	99,70	99,80	99,80
OSNR		93,40	94,40	94,33	94,30	93,50	93,30	94,70
CD	650	99,60	99,63	99,50	99,70	99,33	99,70	99,57
przenik		99,80	99,80	99,83	99,90	99,90	99,83	99,90
OSNR		94,70	94,90	95,43	95,20	94,83	95,60	95,10
CD	750	99,60	99,60	99,53	99,60	99,30	99,73	99,73
przenik		99,90	99,90	99,83	99,90	99,73	99,70	99,80
OSNR		95,30	95,00	95,73	95,40	95,10	95,20	95,50
CD	850	99,73	99,47	99,57	99,53	99,33	99,40	99,47
przenik		99,83	99,80	99,73	99,90	99,80	99,83	99,80
OSNR		94,80	95,13	94,83	95,40	94,90	95,50	95,20
CD	950	98,87	99,67	98,83	99,63	99,50	99,33	99,17
przenik		99,90	99,73	99,73	99,80	99,80	99,90	99,70
OSNR		95,73	94,53	94,70	95,10	94,90	94,73	95,20
CD	1000	99,43	99,60	99,23	99,40	99,20	99,03	98,80
przenik		99,70	99,80	99,80	99,80	99,80	99,80	99,70
OSNR		95,23	95,10	94,83	94,60	94,50	95,50	94,80

W tab. 6.6 przedstawiono wybrane portrety fazy dla modulacji DPSK i opóźnienia 0,5 bit.

Tabela 6.6 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 0,5 bit.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	1150,256	1150,363	1585,608	1585,404	512,404	511,530	1460,704	1463,741
Przenik [dB]	37,537	37,528	11,668	11,722	29,403	29,374	18,711	18,703
OSNR [dB]	34,092	34,052	11,741	11,558	22,228	22,318	13,928	13,935
Portret fazy								
CD [ps/nm]	469,853	470,717	769,858	770,923	1170,183	1169,396	1408,728	1407,492
Przenik [dB]	12,074	12,050	29,893	29,815	10,093	10,051	29,276	29,276
OSNR [dB]	14,643	14,611	22,756	22,644	15,409	15,455	20,306	20,332
Portret fazy								
CD [ps/nm]	895,080	885,777	1257,902	1256,423	893,254	895,117	1050,530	1050,042
Przenik [dB]	17,794	17,769	15,017	15,047	11,326	11,297	26,112	26,258
OSNR [dB]	10,965	11,007	29,246	29,091	20,433	20,282	26,686	26,541
Portret fazy								
CD [ps/nm]	430,109	429,929	461,117	462,586	1041,32	1041,742	1557,224	1556,450
Przenik [dB]	6,000	5,948	20,388	20,405	24,251	24,478	27,042	27,023
OSNR [dB]	10,169	10,057	23,661	23,684	26,102	26,142	16,015	16,076
Portret fazy								
CD [ps/nm]	1382,930	1385,551	578,358	577,643	1547,578	1545,816	658,856	658,194
Przenik [dB]	14,474	14,447	18,807	18,856	32,987	32,934	37,942	37,957
OSNR [dB]	14,844	14,749	16,335	16,415	9,823	9,809	36,543	36,555
Portret fazy								
CD [ps/nm]	551,145	552,622	1535,483	1534,735	738,654	738,543	927,426	928,413
Przenik [dB]	13,149	13,184	14,006	13,983	27,862	27,868	12,098	12,051
OSNR [dB]	29,423	29,384	25,438	25,470	15,574	15,539	14,064	14,038

















































W tab. 6.7 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,5 bit.

Tabela 6.7 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,5 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

R^2 dla zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	98,90	98,50	98,27	97,77	97,20	98,47	97,80
przenik		94,70	94,30	93,90	94,03	92,90	94,73	91,83
OSNR		86,50	86,93	85,20	85,10	88,03	82,13	82,70
CD	75	98,17	97,37	98,27	97,87	98,30	98,13	98,87
przenik		96,43	95,30	96,60	96,00	95,13	95,73	96,63
OSNR		90,50	91,53	88,60	89,73	86,90	90,20	89,13
CD	100	97,70	98,60	98,77	98,53	98,20	98,50	98,43
przenik		96,20	96,20	97,20	97,13	96,90	97,33	96,90
OSNR		93,63	90,00	92,20	92,90	89,90	92,13	92,80
CD	150	98,20	98,53	98,60	98,60	98,50	98,47	98,40
przenik		97,23	97,00	96,10	97,20	97,10	97,33	97,20
OSNR		94,20	94,10	94,30	95,10	95,00	94,83	94,90
CD	250	98,67	97,80	98,27	98,23	97,93	98,27	98,83
przenik		97,10	97,30	97,13	97,33	97,30	97,03	97,10
OSNR		95,53	95,23	95,43	95,30	95,60	94,83	95,23
CD	350	98,50	98,30	98,43	98,20	98,13	98,97	98,50
przenik		97,30	96,73	97,03	97,30	97,10	96,93	97,40
OSNR		95,80	95,20	95,10	95,40	95,63	95,73	95,80
CD	450	98,17	98,10	98,67	98,43	97,90	98,37	98,47
przenik		97,50	97,00	97,20	97,43	97,10	97,20	97,23
OSNR		95,80	95,50	95,33	95,33	95,63	95,40	95,40
CD	650	98,20	98,80	98,50	98,57	98,40	98,53	98,40
przenik		97,40	97,03	96,73	97,40	96,83	97,33	97,10
OSNR		95,93	95,90	96,13	96,13	96,10	95,90	95,93
CD	750	98,20	98,50	98,53	98,63	98,70	98,57	98,50
przenik		96,80	97,30	97,20	97,13	97,10	96,90	97,53
OSNR		96,10	96,00	95,90	96,00	96,10	96,40	96,33
CD	850	98,47	98,20	98,73	98,33	98,43	98,43	98,50
przenik		97,30	97,23	97,50	97,10	97,00	96,90	97,30
OSNR		95,93	95,80	96,00	95,73	95,63	96,00	95,73
CD	950	98,27	98,27	98,23	98,57	98,10	97,87	97,57
przenik		97,03	97,00	97,00	97,30	97,13	97,00	97,20
OSNR		95,53	96,00	95,93	95,90	95,80	95,53	95,90
CD	1000	97,80	97,30	98,50	98,53	98,10	97,33	97,00
przenik		97,23	96,90	97,23	97,00	97,10	97,40	97,00
OSNR		95,63	96,13	95,70	96,00	95,80	95,60	95,80

W tab. 6.8 przedstawiono wybrane portrety fazy dla modulacji OOK i opóźnień 0,5 bit.

Tabela 6.8 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnień 0,5 bit.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	478,560	478,419	441,931	442,717	539,259	539,930	1585,608	1583,998
Przenik [dB]	19,550	19,500	10,868	10,877	28,952	28,863	11,668	11,655
OSNR [dB]	25,626	25,465	20,565	20,424	11,126	10,632	11,741	11,743
Portret fazy								
CD [ps/nm]	1539,555	1539,003	1193,823	1195,285	972,474	974,236	664,974	666,867
Przenik [dB]	38,887	38,890	15,298	15,071	28,373	28,341	22,294	22,225
OSNR [dB]	16,634	16,660	19,417	19,438	13,612	13,527	27,000	27,005
Portret fazy								
CD [ps/nm]	536,180	536,731	932,680	932,430	907,269	907,297	1116,574	1114,262
Przenik [dB]	38,417	38,239	15,793	15,780	26,862	26,832	8,921	8,803
OSNR [dB]	32,051	31,853	11,640	11,611	29,831	29,831	37,498	37,440
Portret fazy								
CD [ps/nm]	1286,947	1288,797	1591,824	1594,775	1108,352	1107,292	974,157	968,593
Przenik [dB]	6,406	6,350	18,410	18,337	28,616	28,519	24,173	24,109
OSNR [dB]	20,104	20,116	23,984	24,030	14,976	14,841	11,974	11,965
Portret fazy								
CD [ps/nm]	722,572	721,485	469,177	471,582	844,010	844,431	1313,127	1316,215
Przenik [dB]	21,453	21,425	18,427	18,303	12,713	12,664	11,574	11,495
OSNR [dB]	18,480	18,380	35,482	35,457	22,270	22,140	26,253	26,385
Portret fazy								
CD [ps/nm]	512,404	512,714	1098,941	1098,468	604,723	606,608	462,675	462,355
Przenik [dB]	29,403	29,403	12,714	12,414	25,483	25,492	14,262	14,270
OSNR [dB]	22,228	22,219	25,727	25,646	10,681	10,621	28,922	28,788

























W tab. 6.9 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 1 bit.

Tabela 6.9 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 1 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

R^2 dla zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	97,73	98,70	98,70	98,47	98,43	98,43	98,20
przenik		99,50	99,63	99,40	99,40	99,50	99,10	99,53
OSNR		74,80	77,80	71,00	76,63	77,43	73,13	74,53
CD	75	99,00	99,13	99,47	98,80	98,30	98,97	98,80
przenik		99,70	99,80	99,60	99,63	99,80	99,53	99,70
OSNR		75,33	80,73	83,40	80,80	80,90	84,90	83,83
CD	100	98,17	99,13	99,37	99,10	98,97	99,27	99,17
przenik		99,60	99,80	99,63	99,80	99,80	99,70	99,70
OSNR		87,73	86,33	89,70	84,50	84,40	88,00	86,30
CD	150	99,37	99,47	99,40	99,33	98,70	99,33	99,47
przenik		99,60	99,80	99,70	99,73	99,80	99,60	99,93
OSNR		92,20	84,30	92,30	91,80	88,90	91,80	90,00
CD	250	99,10	99,30	99,30	99,43	98,60	99,43	99,20
przenik		99,80	99,83	99,70	99,60	99,70	99,73	99,70
OSNR		93,70	94,03	93,00	93,53	95,00	93,50	93,50
CD	350	99,13	99,37	99,07	99,20	99,00	99,37	99,40
przenik		99,73	99,70	99,70	99,63	99,70	99,70	99,60
OSNR		94,13	94,30	94,50	94,60	93,83	94,13	94,20
CD	450	98,87	98,40	98,83	98,60	99,00	99,00	98,73
przenik		99,60	99,73	99,70	99,70	99,70	99,70	99,60
OSNR		93,10	94,90	94,40	93,33	93,90	93,30	94,40
CD	650	99,23	99,47	98,97	99,33	99,10	99,27	99,10
przenik		99,80	99,63	99,70	99,70	99,70	99,70	99,73
OSNR		95,10	94,60	95,30	95,00	94,83	95,30	94,70
CD	750	99,20	99,40	99,00	99,30	99,03	99,00	98,57
przenik		99,70	99,60	99,70	99,73	99,63	99,80	99,70
OSNR		94,60	94,70	95,43	95,50	94,90	94,90	95,00
CD	850	98,80	99,27	99,03	99,27	98,87	98,87	98,40
przenik		99,60	99,73	99,70	99,63	99,73	99,73	99,70
OSNR		95,10	94,80	95,13	94,80	95,30	94,90	95,00
CD	950	98,50	99,23	98,97	99,00	99,20	98,20	98,40
przenik		99,60	99,70	99,73	99,70	99,70	99,70	99,50
OSNR		94,40	94,50	94,83	95,30	95,10	94,90	95,10
CD	1000	98,20	98,77	98,03	98,63	98,67	98,27	98,40
przenik		99,80	99,70	99,73	99,63	99,63	99,63	99,60
OSNR		94,80	94,93	94,80	94,90	94,50	94,63	94,90

W tab. 6.10 przedstawiono wybrane portrety fazy dla modulacji DPSK i opóźnienia 1 bit.

Tabela 6.10 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 1 bit.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	512,404	511,378	844,010	845,821	1242,360	1241,330	868,360	873,553
Przenik [dB]	29,403	29,398	12,713	12,713	18,431	18,414	29,420	29,341
OSNR [dB]	22,228	22,097	22,270	22,218	27,836	27,760	6,051	6,000
Portret fazy								
CD [ps/nm]	598,470	597,305	1556,320	1563,460	917,147	915,155	1076,214	1077,560
Przenik [dB]	21,539	21,537	15,536	15,543	10,196	10,198	28,470	28,446
OSNR [dB]	12,888	12,838	10,115	10,045	22,335	22,587	20,397	20,386
Portret fazy								
CD [ps/nm]	1504,560	1502,985	1021,818	1023,209	920,163	917,975	1409,943	1409,785
Przenik [dB]	26,680	26,667	17,047	17,028	6,969	6,984	9,675	9,645
OSNR [dB]	23,303	23,205	11,567	11,524	14,685	14,830	20,106	20,190
Portret fazy								
CD [ps/nm]	1372,645	1373,778	1217,349	1219,563	1094,181	1093,511	1171,111	1170,653
Przenik [dB]	15,835	15,785	13,825	13,990	27,644	27,656	17,543	17,588
OSNR [dB]	28,589	28,892	35,083	35,081	19,590	19,593	29,645	29,708
Portret fazy								
CD [ps/nm]	806,890	803,243	457,532	456,541	1460,704	1462,128	418,491	418,314
Przenik [dB]	11,038	11,001	38,727	38,670	18,711	18,627	28,991	29,010
OSNR [dB]	13,575	13,80	29,689	29,841	13,928	13,992	16,828	16,782
Portret fazy								
CD [ps/nm]	1016,760	1021,432	925,503	932,784	551,153	553,284	1324,839	1340,567
Przenik [dB]	24,520	24,724	15,020	15,230	13,157	13,272	11,492	11,508
OSNR [dB]	12,090	12,115	20,694	20,359	29,421	29,697	17,553	17,692











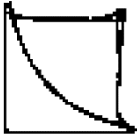













W tab. 6.11 przedstawiono dokładność wyznaczania parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 1 bit.

Tabela 6.11 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 1 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.

R^2 dla zjawiska	Liczba epok	Numer zestawu						
		1	2	3	4	5	6	7
		Liczba węzłów w warstwach w pełni połączonych						
		384/128	512/256	512/128	384/256	384/64	384/384	512/512
CD	50	95,97	98,47	97,23	95,93	96,63	95,20	97,23
przenik		95,00	94,10	94,80	94,00	94,30	95,00	90,20
OSNR		79,73	80,80	80,90	82,10	78,30	80,50	79,60
CD	75	97,33	98,10	97,97	97,20	97,00	96,77	98,23
przenik		96,50	96,50	96,60	96,30	96,00	92,10	91,30
OSNR		85,90	84,40	85,13	85,00	88,10	86,73	86,80
CD	100	97,50	98,37	97,90	97,37	97,70	97,80	98,70
przenik		97,03	96,90	97,30	96,50	96,80	96,40	96,70
OSNR		89,80	86,80	92,03	88,33	88,63	88,23	90,30
CD	150	97,47	98,27	97,97	98,40	97,93	98,23	97,97
przenik		96,83	97,00	97,43	97,10	97,40	97,00	96,40
OSNR		92,40	93,50	92,30	92,80	93,10	91,00	93,03
CD	250	98,27	98,77	98,03	98,07	97,80	97,80	97,97
przenik		97,10	96,90	97,50	97,13	96,90	97,13	97,10
OSNR		93,90	92,70	94,20	93,30	93,80	93,63	94,20
CD	350	98,47	97,43	97,97	98,10	97,97	98,23	97,40
przenik		97,50	97,33	97,40	97,13	96,60	97,00	97,20
OSNR		93,50	94,40	94,60	94,23	94,10	94,10	94,53
CD	450	97,63	97,87	97,80	96,57	97,40	98,50	96,60
przenik		96,70	97,00	97,00	97,20	97,00	97,03	96,90
OSNR		94,50	94,40	94,20	93,80	94,03	93,40	94,60
CD	650	97,83	98,33	98,40	98,30	98,23	98,20	97,93
przenik		97,23	97,30	97,33	97,50	97,00	96,80	97,00
OSNR		95,03	95,33	94,73	94,90	94,70	94,80	95,00
CD	750	97,63	98,23	97,87	98,27	97,93	97,97	98,00
przenik		97,23	97,10	97,20	97,20	97,10	97,00	97,20
OSNR		94,90	94,73	95,20	94,63	94,63	94,90	94,63
CD	850	98,17	97,57	97,80	97,90	97,67	97,93	97,43
przenik		97,10	96,73	96,93	97,50	97,40	97,10	97,03
OSNR		94,70	94,80	95,00	94,80	94,70	94,60	94,63
CD	950	97,93	97,90	98,03	97,80	97,77	97,50	97,53
przenik		97,20	97,03	97,10	97,60	97,13	96,83	97,00
OSNR		94,40	94,70	95,00	94,30	94,70	94,50	94,70
CD	1000	97,53	97,70	97,53	97,10	97,00	97,83	96,97
przenik		97,50	97,10	96,60	97,23	97,33	97,40	97,00
OSNR		94,90	94,50	94,50	94,50	94,23	94,70	95,23

W tab. 6.12 przedstawiono wybrane portrety fazy dla modulacji OOK i opóźnienia 1 bit.

Tabela 6.12 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnienia 1 bit.

	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana	Zadana	Uzyskana
Portret fazy								
CD [ps/nm]	478,560	479,076	441,931	441,116	539,259	538,910	1203,101	1201,902
Przenik [dB]	19,550	19,548	10,868	10,966	28,953	28,937	29,901	29,797
OSNR [dB]	25,626	25,684	20,565	20,577	11,126	11,013	20,028	19,935
Portret fazy								
CD [ps/nm]	1386,398	1384,290	411,286	411,510	1063,664	1062,679	1418,621	1420,425
Przenik [dB]	25,184	25,200	36,831	36,698	16,894	16,841	14,298	14,317
OSNR [dB]	16,331	16,272	8,404	8,335	16,219	16,144	17,310	17,289
Portret fazy								
CD [ps/nm]	786,488	784,235	1028,267	1028,510	411,680	410,957	868,849	869,094
Przenik [dB]	17,314	17,360	25,910	25,864	27,565	27,645	6,831	6,815
OSNR [dB]	24,375	24,422	25,365	25,355	29,180	29,191	32,917	32,939
Portret fazy								
CD [ps/nm]	545,619	543,462	1286,947	1285,738	501,619	500,934	699,907	702,778
Przenik [dB]	11,231	11,252	6,406	6,401	25,580	25,279	26,812	26,600
OSNR [dB]	29,944	29,892	20,104	20,133	11,208	11,180	27,640	27,763
Portret fazy								
CD [ps/nm]	756,107	754,185	533,863	532,497	1545,504	1544,422	1182,243	1185,593
Przenik [dB]	25,659	25,695	7,007	7,050	29,991	29,910	23,318	23,265
OSNR [dB]	28,344	28,450	8,824	8,846	28,949	28,885	12,631	12,492
Portret fazy								
CD [ps/nm]	897,776	896,652	809,292	807,028	1222,184	1223,170	1307,780	1307,192
Przenik [dB]	22,483	22,433	15,609	15,601	14,572	14,584	22,003	22,030
OSNR [dB]	18,657	18,635	23,103	23,086	16,643	16,467	37,664	37,577

W tabelach 6.13 – 6.15 zamieszczono podsumowanie procesu wyznaczania wartości parametrów opisujących zjawiska zachodzące w warstwie fizycznej z wykorzystaniem gotowych modeli nauczonej sieci spłotowej dla modulacji DPSK i OOK. Przedstawione wyniki należy interpretować w następujący sposób: np. CD 99,70% oraz epoka/i 150 oznaczają, że największą dokładność dla zestawu numer 1 dla zjawiska dyspersji chromatycznej, opóźnienia 0,25 bitu i modulacji DPSK uzyskano dla 150 epok i spośród 3000 zmierzonych parametrów, opracowana metoda wskazała poprawnie wartości w 2991 przypadkach (co stanowi łącznie 99,70%). W analogiczny sposób należy interpretować wartości podane w innych komórkach. W tabelach (6.13 – 6.15) zostały podkreślone wartości, wskazujące najwyższą uzyskaną dokładność spośród wszystkich zestawów dla każdego zjawiska.

W tab. 6.13 przedstawiono wyniki dla opóźnienia 0,25 bitu.

Tabela 6.13 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 0,25 bit dla modulacji DPSK i OOK.

	Numer zestawu						
	1	2	3	4	5	6	7
Modulacja DPSK, opóźnienie 0,25 bit							
CD	99,70%	99,70%	<u>99,83%</u>	99,73%	99,73%	99,73%	99,60%
epoka/i	150	950	150	650	650	750	100, 150, 250, 650
przenik	99,70%	99,80%	99,73%	<u>99,83%</u>	99,73%	99,73%	99,80%
epoka/i	750	650, 750	850	350	950, 1000	150	850
OSNR	94,50%	94,80%	94,70%	94,83%	<u>95,03%</u>	94,8%	94,83%
epoka/i	650, 750	650	750	850	650	650	650
Modulacja OOK, opóźnienie 0,25 bit							
CD	98,27%	<u>98,90%</u>	98,50%	98,50%	98,17%	98,37%	98,43%
epoka/i	750, 950	250	75	850	850	850	100
przenik	97,30%	97,03%	97,13%	96,90%	<u>97,60%</u>	97,30%	97,13%
epoka/i	850	850	350	250	850	650	150
OSNR	95,40%	<u>95,90%</u>	95,70%	95,53%	95,30%	95,53%	95,43%
epoka/i	750	850	650	950	850	650	750

Dla opóźnienia 0,25 bitu (tabela 6.13) dla modulacji DPSK i zjawiska dyspersji chromatycznej najlepszą dokładność uzyskano dla modelu z zestawu numer 3. Na 3000 przypadków gotowy model poprawnie wskazał 2995 wartości. Taką samą dokładność uzyskano dla zestawu numer 4 dla zjawiska przeniku. Dla szumu ASE dla najlepszego modelu z zestawu numer 5 uzyskano dokładność wyznaczania parametru OSNR na poziomie 95% co przekłada się na 2851 poprawnych wartości. Najlepsze wyniki uzyskiwano kolejno dla epok 150, 350 oraz 650. W przypadku modulacji OOK dla dyspersji chromatycznej uzyskano dokładność 98,90%

(2967/3000) dla 250 epok i zestawu numer 2; 97,60% (2928/3000) dla przeniku dla 850 epok oraz zestawu numer 5. Dla 850 epok i zestawu numer 2 otrzymano najlepszą dokładność wyznaczania wartości parametru OSNR, 95,90% (2877/3000). Dla modulacji DPSK uzyskano lepsze wyniki wyznaczania wartości parametrów dla zjawisk dyspersji chromatycznej i przeniku. W przypadku parametru OSNR, lepsze wyniki uzyskano dla modulacji OOK. Dla zjawiska dyspersji chromatycznej w obu modulacjach najlepszy wynik wyznaczania wartości parametrów uzyskano dla modeli sieci nauczonych dla mniejszej liczby epok. Dla pozostałych zjawisk w przypadku DPSK najlepsze wyniki uzyskano przeważnie dla modeli sieci nauczonych dla 150, 650, 750 epok. Dla modulacji OOK, najlepsze wyniki wyznaczania wartości parametrów dla zjawiska przeniku oraz parametru OSNR uzyskano dla 850 epok. W tab. 6.14 przedstawiono wyniki dla opóźnienia 0,5 bitu.

Tabela 6.14 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 0,5 bit dla modulacji DPSK i OOK.

	Numer zestawu						
	1	2	3	4	5	6	7
Modulacja DPSK, opóźnienie 0,5 bit							
CD	99,73%	99,77%	99,70%	99,80%	99,50%	99,77%	99,77%
epoka/i	850	250	250	150	350, 950	250	250
przenik	99,90%	99,93%	99,83%	99,90%	99,90%	99,90%	99,90%
epoka/i	100, 150, 750, 950	150	650, 750	250, 650, 750, 850	650	150, 950	150, 650
OSNR	95,73%	95,13%	95,73%	95,40%	95,10%	95,60%	95,50%
epoka/i	950	850	750	750, 850	750	650	750
Modulacja OOK, opóźnienie 0,5 bit							
CD	98,90%	98,80%	98,77%	98,63%	98,70%	98,97%	98,87%
epoka/i	50	650	100	750	750	350	75
przenik	97,50%	97,30%	97,50	97,43%	97,30%	97,40%	97,53%
epoka/i	650	250, 750	850	450	250	1000	750
OSNR	96,10%	96,13%	96,13%	96,13%	96,10%	96,40%	96,33%
epoka/i	750	1000	650	650	650, 750	750	750

Dla opóźnienia 0,5 bit (tabela 6.14) dla modulacji DPSK dla zjawiska dyspersji chromatycznej oraz przeniku uzyskano kolejno 99,80% (2994/3000, zestaw numer 4) oraz 99,93% (2998/3000, zestaw numer 2) w obu przypadkach dla 150 epok. Najlepsze wartości OSNR uzyskano dla zestawów numer 1 i 3 równą 95,73% (2872/3000). Dla zjawisk przeniku oraz OSNR uzyskano lepsze wyniki niż dla opóźnienia 0,25. Dodatkowo dla zjawisk dyspersji chromatycznej oraz przeniku wystarczyły modele sieci nauczonych do 150 epok, aby uzyskać najlepsze rezultaty wyznaczanych wartości parametrów. Dla modulacji OOK dla wszystkich

wartości uzyskano zbliżone lub nieznacznie lepsze wyniki względem opóźnienia 0,25 bit. Dla zjawisk przeniku oraz OSNR najlepsze wyniki uzyskano dla modeli sieci nauczonych dla wyższej liczby epok.

W tab. 6.15 przedstawiono wyniki dla opóźnienia 1 bitu dla modulacji.

Tabela 6.15 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 1 bit oraz modulacji DPSK i OOK.

	Numer zestawu						
	1	2	3	4	5	6	7
Modulacja DPSK, opóźnienie 1 bit							
CD	99,37%	99,47%	99,47%	99,43%	99,20%	99,43%	99,47%
epoka/i	150	150, 650	75	250	950	250	150
przenik	99,80%	99,83%	99,73%	99,80%	99,80%	99,80%	99,93%
epoka/i	250, 650, 1000	250	950, 1000	100	75, 100, 150	750	150
OSNR	95,10%	94,93%	95,43%	95,50%	95,30%	95,30%	95,10%
epoka/i	650, 850	1000	750	750	850	650	950
Modulacja OOK, opóźnienie 1 bit							
CD	98,47%	98,77%	98,40%	98,40%	98,23%	98,50%	98,70%
epoka/i	350	250	650	150	650	450	100
przenik	97,50%	97,33%	97,50%	97,60%	97,40%	97,40%	97,20%
epoka/i	350, 1000	350	250	950	150, 850	1000	350, 750
OSNR	95,03%	95,33%	95,20%	94,90%	94,70%	94,90%	95,23%
epoka/i	650	650	750	650	650, 850, 950	750	1000

W ostatnim przypadku dla opóźnienia 1 bit (tabela 6.15) dla modulacji DPSK otrzymano najslabszy wynik wyznaczania wartości parametrów opisujących zjawisko dyspersji chromatycznej 99,47% (2984/3000) względem poprzednich opóźnień bitowych. Taki wynik uzyskano dodatkowo dla dwóch innych zestawów danych. Warto zaznaczyć, że wynik ponad 99% dokładności uzyskano dla modelu sieci nauczonej dla 75 epok. Dodatkowo otrzymano taką samą dokładność przeniku 99,93% (2998/3000) jak dla opóźnienia 0,5 bit. Wynik wyznaczania wartości OSNR był lepszy niż dla opóźnienia 0,25 bit. Dla modulacji OOK uzyskano gorsze wyniki w odniesieniu do poprzednich opóźnień dla zjawiska dyspersji chromatycznej i parametru OSNR. Otrzymano również taki sam wynik wyznaczania wartości parametrów dla zjawiska przeniku jak dla opóźnienia 0,25 bit. Dla modulacji OOK dla opóźnienia 1 bit wyniki dla poszczególnych zjawisk okazały się gorsze niż dla modulacji DPSK.

W ramach podsumowania danych z tab. 6.13 – 6.15 ustalono następujące wnioski:

- dla obu rodzajów modulacji najlepsze wyniki wyznaczania wartości parametrów opisujących równocześnie występujące zjawisk uzyskano dla opóźnienia 0,5 bit.
- dla modulacji DPSK dla zjawiska dyspersji chromatycznej i przeniku uzyskano we wszystkich przypadkach lepsze wyniki niż dla modulacji OOK. Ponadto najlepsze wyniki dla modulacji DPSK otrzymano dla modeli sieci nauczonych dla małej liczby epok (75, 100, 150).
- dla modulacji OOK i zjawiska szumu ASE uzyskano dla opóźnień bitowych 0,25 oraz 0,5 wyraźne lepsze wyniki parametru OSNR niż dla modulacji DPSK. Może to być spowodowane kształtem portretów fazy. Dla modulacji DPSK portrety dla wspomnianych opóźnień zajmują mniejszą powierzchnię wzdłuż przekątnej kwadratu o wymiarze 50 x 50 pikseli w odniesieniu dla analogicznych portretów dla modulacji OOK. Uzyskane wyniki mogą oznaczać, że modele opisujące nauczone sieci będą dokładniejsze, gdy zestawy danych treningowych będą posiadały bardziej różnorodne kształty.
- najlepsze wyniki dla zjawiska szumu ASE dla wszystkich typów opóźnień, modulacji oraz badanych zestawów uzyskiwano dla modeli sieci nauczonych dla liczby epok od 650 do 1000.
- dla modulacji DPSK dla opóźnienia 1 bit, uzyskano nieznacznie lepszą dokładność wyznaczania wartości dla parametru OSNR niż dla modulacji OOK.
- dla modulacji OOK w procesie wyznaczania wartości parametrów nie udało się uzyskać dla żadnego zjawiska dokładności powyżej 99%.
- liczba epok ma istotny wpływ na dokładność uzyskiwaną w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska. Wysoki współczynnik dopasowania uzyskany po przeprowadzonym procesie uczenia nie zawsze musi oznaczać wysoką dokładność modelu w późniejszym jego wykorzystaniu w trakcie wyznaczania wartości mierzonego zjawiska. W przypadku zjawiska szumu ASE dla modeli o podobnym współczynniku dopasowania lepsze wyniki w wyznaczaniu wartości parametrów uzyskano dla modeli z nauczoną siecią dla wyższej liczby epok. Dodatkowo należy zwrócić uwagę na parametr średniej wartości błędu gotowego modelu. Dla modeli opisujących nauczoną sieć dla większej liczby epok jest on zdecydowanie niższy. Przeprowadzone badania udowodniły, że model z wysokim współczynnikiem dopasowania będzie wyznaczał wartości parametru opisującego

monitorowane zjawisko ze zdecydowanie niższym błędem, niż model dla mniejszej liczby epok, ale z takim samym lub wyższym współczynnikiem dopasowania.

- liczba węzłów w warstwach połączonych ma pomijalny wpływ na wynik końcowy w procesie wyznaczania wartości parametrów. Trudno jest wskazać najlepszy zestaw z siedmiu przebadanych, ponieważ dla każdego udało się uzyskać najlepsze rezultaty dla części spośród badanych modulacji i opóźnień.

Z powyższej analizy wynika, że aby algorytmy CNN zapewniły wysoką dokładność wyznaczania wartości parametrów opisujących monitorowane zjawiska należy zapewnić do jej nauki duży zestaw danych uczących (w przypadku prezentowanych badań 62000). Dodatkowo sam proces uczenia musi zostać przeprowadzony dla odpowiedniej liczby epok. Nie da się jednak wskazać jednej konkretnej wartości, ponieważ jest ona zależna od typu modulacji oraz od rodzaju występującego zjawiska. Na przykład w przypadku uczenia sieci na rozpoznawanie zjawiska szumu ASE, które jest reprezentowane przez parametr OSNR, model musiał być nauczony dla znacznie większej liczby epok niż dla zjawisk dyspersji chromatycznej oraz przeniku. Dodatkowo w ujęciu ogólnym najlepsze wartości monitorowania uzyskano w większości przypadków dla opóźnienia 0,5 bitu.

Porównanie wyników z dostępnymi badaniami

Uzyskane wyniki w procesie wyznaczania wartości wybranych parametrów monitorowanych zjawisk z wykorzystaniem modeli nauczonych sieci splotowych są bardzo dobre. Elastyczność sieci splotowych umożliwia dodatkowo zwiększenie dokładności poprzez zmianę monitorowanego zakresu poszczególnych zjawisk. Jak wykazano w [94] zmniejszając zakres monitorowania dla dyspersji chromatycznej z 200 – 1800 ps/nm do 400 – 1600 ps/nm oraz dla przeniku z 5 – 40 dB do 10 – 30 dB, udało się zwiększyć dokładność monitorowania obu zjawisk dla modulacji OOK do 99,9% dla dyspersji chromatycznej i 99,3% dla przeniku. Wzrost dokładności udało się również uzyskać dla szumu ASE, a dokładność monitorowania parametru OSNR zwiększyła się do prawie 97%.

W tab. 6.16 zestawiono wyniki uzyskane w ramach przeprowadzonych badań oraz dostępne z dwóch prac naukowych [90], [91]. Bezpośrednie porównanie wartości poszczególnych parametrów nie jest możliwe, ponieważ w obu dostępnych pracach monitorowano równocześnie dyspersję chromatyczną i polaryzacyjną oraz szum ASE, natomiast w ramach rozprawy doktorskiej dyspersję chromatyczną, przenik oraz szum ASE. W wynikach przedstawionych w [90] uzyskano gorsze wartości względem tych z [91], dlatego dalsze ich omawianie zostanie pominięte. W wynikach z [91] dla sygnału 10 Gbit/s NRZ-DPSK uzyskano błąd monitorowania parametru OSNR 0,38 dB, dyspersji chromatycznej 1,53 ps/nm

oraz DGD 0,48 ps. Względem wyników z rozprawy doktorskiej uzyskano lepszą dokładność parametru OSNR o 0,15 dB oraz gorszą dla dyspersji chromatycznej o 0,29 ps/nm. W przypadku sygnału 10 Gbit/s NRZ-OOK w zewnętrznych badaniach uzyskano błąd monitorowania OSNR o wartości 0,47 dB i 1,30 ps/nm dla dyspersji chromatycznej względem OSNR 0,39 dB i dyspersji chromatycznej 1,46 ps/nm dla wyników z rozprawy. Dla tego sygnału w rozprawie uzyskano lepszą dokładność dla OSNR równą 0,08 dB oraz gorszą dla dyspersji chromatycznej równą 0,16 ps/nm.

Tabela 6.16 Porównanie wyników otrzymanych w ramach pracy doktorskiej z wynikami istniejącymi.

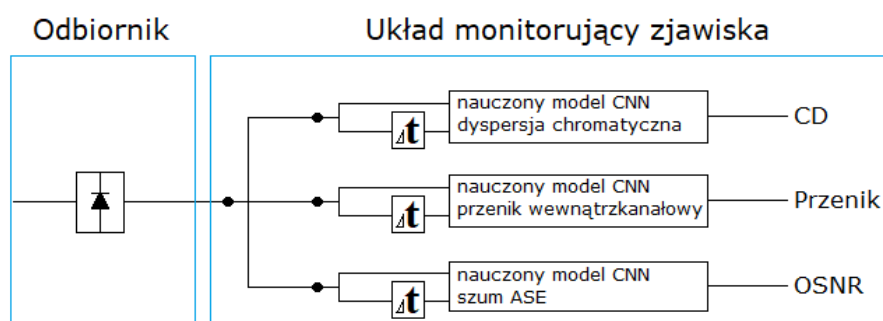
Numer porządkowy	Monitorowane parametry	Mierzony zakres	Średni błąd monitorowania	Formaty modulacji, przepływność
1 źródło: [90]	OSNR	10 – 28 dB	0,81 dB	QPSK, 16QAM, 65QAM 60, 100 Gbit/s
	CD	0 – 450 ps/nm	1,52 ps/nm	
	DGD	0 – 10 ps	0,32 ps	
2 źródło: [91]	OSNR	10 – 28 dB	0,38 dB	NRZ-DPSK 10 Gbit/s
	CD	0 – 450 ps/nm	1,53 ps/nm	
	DGD	0 – 10 ps	0,48 ps	
	OSNR	10 – 28 dB	0,47 dB	NRZ-OOK 10 Gbit/s
	CD	0 – 450 ps/nm	1,30 ps/nm	
DGD	0 – 10 ps	0,62 ps		
3 wyniki własne	OSNR	5 – 40 dB	0,53 dB	NRZ-DPSK, 10 Gbit/s
	CD	200 – 1800 ps/nm	1,24 ps/nm	
	przenik	5 – 40 dB	0,06 dB	NRZ-OOK, 10 Gbit/s
	OSNR	5 – 40 dB	0,39 dB	
	CD	200 – 1800 ps/nm	1,46 ps/nm	
przenik	5 – 40 dB	0,23 dB		

Wyniki przedstawione w [91] mogą wydawać się porównywalne z uzyskanymi w ramach rozprawy doktorskiej. Należy jednak zwrócić uwagę, że badania te zostały wykonane w znacznie węższym zakresie pomiarowym 10 - 28 dB dla OSNR (z krokiem 2 dB) oraz 0 - 450 dla dyspersji chromatycznej (z krokiem 50 ps/nm) względem zakresów 5 - 40 dla OSNR i 200 - 1800 dla dyspersji chromatycznej przedstawionych w rozprawie. W pracy [91] zapewniono również małą liczbę portretów fazy do zestawu uczącego wynoszącą 1100 obrazów. Przy zastosowanych proporcjach 90% - zestaw uczących i 10% - zestaw testowy, dokładność zaprezentowanej metody przetestowano tak naprawdę na 110 obrazach. To stanowczo za mało. W ramach rozprawy doktorskiej wygenerowano po 62000 obrazów na każdy przypadek, a dokładność uzyskanych modeli przetestowano dla zestawu testowego składającego się z 9300 portretów fazy (15%). Następnie ponowiono testowanie modeli z wykorzystaniem 3000 dodatkowych portretów fazy. Wyniki przedstawione w [91] są mało miarodajne. Doświadczenie uzyskane w trakcie badań wskaże, że przy zestawie danych

zbudowanych z tak małej liczby obrazów oraz wąskim zakresie pomiarowym z dużym krokiem między kolejnymi wartościami w przypadku wystąpienia zakłóceń innych niż z przyjętych przedziałów gotowy model najpewniej wskaże bardzo duży błąd. Podobny błąd w metodyce pomiarowej zaobserwowano już w pracy [87], o czym autorzy wspomnieli we wnioskach końcowych. Dodatkowo monitorowany parametr DGD w zakresie 0 - 10 ps ma w rzeczywistości mały wpływ na zakłócenia widoczne w ramach portretów fazy. Dyspersja polaryzacyjna powoduje lekkie zaokrąglenie dwóch narożników wykresu. Współistnienie tego zjawiska w przedstawionych badaniach nie ma wielkiego wpływu na demonstrację dokładności uzyskanych modeli, ponieważ są tam widoczne głównie nałożone zjawiska dyspersji chromatycznej i szumu ASE. W ramach rozprawy doktorskiej monitorowany jest (jako trzecie zjawisko) przenik optyczny w zakresie 5 do 40 dB.

Przy zademonstrowanych wynikach w ramach własnej pracy użyto bardzo dużej liczby punktów pomiarowych wraz z szerokim zakresem równocześnie występujących zjawisk. Przeprowadzono również dodatkowe sprawdzenie modeli na dodatkowych danych. Takie podejście zapewnia, że dokładność wyznaczania parametrów opisujących monitorowane zjawiska będzie bardzo wysoka, niezależnie od intensywności występowania innych zjawisk.

Na rys. 6.1 przedstawiono schemat monitorowania zjawisk dyspersji chromatycznej, przeniku wewnątrzkanałowego oraz szumu ASE. Odebrany sygnał zostaje rozdzielony i trafia do trzech bloków odpowiedzialnych za każde z wymienionych zjawisk. Każdy blok stanowi gotowy model sieci splotowej, który na wejściu przyjmuje portret fazy monitorowanego sygnału. Wynikiem działania modeli są wartości liczbowe monitorowanych zjawisk.



Rys. 6.1 Układ monitorujący zjawiska dyspersji chromatycznej, przeniku wewnątrzkanałowego oraz szumu ASE.

Dla przedstawionego układu monitorującego proponowane są następujące ustawienia, które należy przyjąć w procesie uczenia sieci splotowej:

- a) modulacja DPSK
 - model dyspersji chromatycznej:

- liczba węzłów w warstwach w pełni połączonych: 512/128,
 - liczba epok: 150,
 - opóźnienie: 0,25 bitu.
 - model przeniku:
 - liczba węzłów w warstwach w pełni połączonych: 512/256,
 - liczba epok: 150,
 - opóźnienie: 0,5 bitu.
 - model szumu ASE:
 - liczba węzłów w warstwach w pełni połączonych: 512/128,
 - liczba epok: 750,
 - opóźnienie: 0,5 bitu.
- b) modulacja OOK
- model dyspersji chromatycznej:
 - liczba węzłów w warstwach w pełni połączonych: 384/384,
 - liczba epok: 350,
 - opóźnienie: 0,5 bitu.
 - model przeniku:
 - liczba węzłów w warstwach w pełni połączonych: 384/64,
 - liczba epok: 850,
 - opóźnienie: 0,25 bitu.
 - model szumu ASE:
 - liczba węzłów w warstwach w pełni połączonych: 384/384,
 - liczba epok: 750,
 - opóźnienie: 0,5 bitu.

Dla każdego modelu należy zapewnić zestaw danych składający się z 62000 portretów faz.

7. Podsumowanie

W wyniku przeprowadzonego procesu uczenia sieci spłotowych z wykorzystaniem danych pochodzących z metody ADTS oraz wykonaniu badań nad zastosowaniem uzyskanych modeli do wyznaczania wartości liczbowych parametrów opisujących równocześnie występujące zjawiska dyspersji chromatycznej, przeniku optycznego i szumu ASE udowodniono postawioną tezę. *Problem monitorowania kilku, równocześnie występujących zjawisk zakłócających transmisję danych w światłowodzie może być efektywnie rozwiązany stosując metodę asynchronicznego próbkowania sygnałów i spłotowe sieci neuronowe.*

Dodatkowo zrealizowano zasadniczy cel pracy. Poza udowodnieniem postawionej tezy opracowano metodę i układ pomiarowy do jej realizacji, umożliwiający mierzenie z dużą dokładnością wartości parametrów opisujących równocześnie występujące zjawiska dyspersji chromatycznej, przeniku oraz szumu ASE dla modulacji DPSK i OOK dla przepływności 10 Gbit/s. Narzędzie może być z powodzeniem wykorzystywane do monitorowania jakości transmisji optycznej w nowoczesnych systemach. Uzyskane wyniki udowodniły, że sieci spłotowe umożliwiają wyznaczanie wartości liczbowych równocześnie występujących zjawisk w szerokim zakresie, a swoimi właściwościami przewyższają inne dostępne metody. Na wysoką dokładność wyznaczanych wartości parametrów opisujących zjawiska nie ma wpływu intensywność równocześnie występujących zakłóceń.

W momencie rozpoczęcia własnych badań [85], technika ADTS w połączeniu ze spłotowymi sieciami neuronowymi była metodą nieznaną w zagadnieniach związanych z równoczesnym monitorowaniem wielu zjawisk w warstwie fizycznej sieci optycznej. Wiadomości zawarte w przedstawionej pracy i wyniki uzyskane po przeprowadzeniu badań (zaprezentowane dodatkowo m.in. w [85], [94]–[98]) wnoszą znaczący wkład w rozwój w dziedzinie monitorowania równocześnie występujących zjawisk w warstwie fizycznej sieci optycznej, ponieważ do tej pory nikt nie przeprowadził tak kompleksowych badań tych metod. Dotychczasowe opublikowane wyniki wyznaczania wartości liczbowych z wykorzystaniem sieci spłotowych w optycznych systemach monitorowania były zazwyczaj kończone po przeprowadzonym pozytywnym procesie uczenia. Okazuje się jednak, że wysoka dokładność gotowego modelu opisującego nauczoną sieć nie zawsze przekłada się na równie dobre wyniki w dalszym procesie wyznaczania wartości i taki model może monitorować parametry z dużym błędem. Z tego względu w celu dodatkowej oceny jakości narzędzia monitorowania, modele należy poddać dalszej weryfikacji na dodatkowych zewnętrznych danych. Zaprezentowane

wyniki uzupełniają brakującą wiedzę dotyczącą monitorowania oraz poruszają kwestię wspomnianych problemów. Nie wyczerpują jednak możliwości do rozwijania i ulepszania techniki. Wskazane jest dalsze prowadzenie badań w kierunku równoczesnego monitorowania większej liczby parametrów oraz optymalizacji minimalnej liczby obrazów z zestawów danych niezbędnych dla procesu uczenia sieci do zachowania wysokiej jakości monitorowania. Konieczne jest również uzupełnienie badań w warunkach rzeczywistych. Do zaproponowanej metody pomiarowej wykorzystującej sieci splotowe wymagana była duża liczba danych uczących (nawet parędziesiąt tysięcy) zawierających kombinację trzech występujących zjawisk o gęstym pokryciu. Tak dużą liczbę portretów fazy, które równocześnie zawierałyby zjawiska o różnej intensywności trudno byłoby uzyskać w warunkach rzeczywistych (w przeciwieństwie do środowiska symulacyjnego). Wymagałoby to zbudowania specjalnego stanowiska do generowania danych oraz bardzo dużego nakładu czasu do ich uzyskania. Z tego względu, zdecydowano się skorzystać ze środowiska symulacyjnego. Po uzyskaniu bardzo dobrych wyników zaprezentowanych w rozprawie doktorskiej zasadne jest jednak podjęcie prac, w trakcie których zostaną wykorzystane rzeczywiste dane.

Literatura

- [1] “X.200 : Information technology - Open Systems Interconnection - Basic Reference Model: The basic model.” <https://www.itu.int/rec/T-REC-X.200-199407-I> (accessed Feb. 18, 2022).
- [2] K. Perlicki, “Pomiary w optycznych systemach telekomunikacyjnych”, WKiŁ, 2002.
- [3] ITU-T Rec. G.697, “Transmission media and optical systems characteristics – Characteristics of optical systems,” 2016.
- [4] A. E. Willner *et al.*, “Optical Performance Monitoring,” *J. Light. Technol. Vol. 22, Issue 1, pp. 294-*, vol. 22, no. 1, pp. 294-, Jan. 2004, Accessed: Oct. 25, 2020. [Online]. Available: <https://www.osapublishing.org/abstract.cfm?uri=jlt-22-1-294>.
- [5] I. P. Kaminow, T. Li, and A. E. Willner, *Optical Fiber Telecommunications: Systems and Networks: Sixth Edition*. Elsevier Inc., 2013.
- [6] K. Perlicki, “Rozwój telekomunikacyjnych sieci optycznych,” no. 1, pp. 21–27, 2001.
- [7] “G.663 : Application-related aspects of optical amplifier devices and subsystems.” <https://www.itu.int/rec/T-REC-G.663-201104-I/en> (accessed Aug. 09, 2021).
- [8] “G.667 : Characteristics of adaptive chromatic dispersion compensators.” <https://www.itu.int/rec/T-REC-G.667-200612-I/en> (accessed Aug. 09, 2021).
- [9] “G.Sup39 : Optical system design and engineering considerations.” <https://www.itu.int/rec/T-REC-G.Sup39-201602-I/en> (accessed Aug. 09, 2021).
- [10] G. P. (Govind P. . Agrawal, “Fiber-optic communication systems,” p. 603, 2010.
- [11] “G.697 : Optical monitoring for dense wavelength division multiplexing systems.” <https://www.itu.int/rec/T-REC-G.697-201611-I/en> (accessed Aug. 09, 2021).
- [12] D. Dahan, U. Mahlab, A. Teixeira, I. Zacharopoulos, and I. Tomkos, “Optical performance monitoring for translucent/transparent optical networks,” *IET Optoelectron.*, vol. 5, no. 1, pp. 1–18, Feb. 2011, doi: 10.1049/iet-opt.2010.0010.
- [13] C. Chan, *Optical Performance Monitoring*. Elsevier Inc., 2010.
- [14] “OTDR Theory and Operation - Operating the OTDR | IEEE Courses | IEEE Xplore.” <https://ieeexplore.ieee.org/courses/details/EDP0129> (accessed Aug. 09, 2021).
- [15] D. Derickson, “Fiber optic test and measurement,” p. 642, 1998.
- [16] M. Fuller and M. Fuller, “OSAs migrate from the lab to the field to the manufacturing floor. (Tech Trends),” *Lightwave*, vol. 19, no. 1, pp. 117-, Jan. 2002.

- [17] C. M. “Jack” Wang, J. A. Jargon, and P. D. Hale, “A Robust Algorithm for Eye-Diagram Analysis,” *J. Light. Technol.* Vol. 26, Issue 21, pp. 3592-3600, vol. 26, no. 21, pp. 3592–3600, Nov. 2008, Accessed: Oct. 25, 2020. [Online]. Available: <https://www.osapublishing.org/abstract.cfm?uri=jlt-26-21-3592>.
- [18] I. Shake, H. Takara, and S. Kawanishi, “Simple Q factor monitoring for BER estimation using opened eye diagrams captured by high-speed asynchronous electrooptical sampling,” *IEEE Photonics Technol. Lett.*, vol. 15, no. 4, pp. 620–622, Apr. 2003, doi: 10.1109/LPT.2003.809316.
- [19] P. Walewski, “Monitorowanie sieci transmisji optycznej metodą asynchronous delay tap sampling” 2013.
- [20] J. R. Meyer-Arendt, S. Kozikowski, J. (1938-). Prochorow, and ZGWN, “Wstęp do optyki,” 1979.
- [21] “G.959.1 : Optical transport network physical layer interfaces.” <https://www.itu.int/rec/T-REC-G.959.1-201807-I/en> (accessed Jul. 23, 2021).
- [22] M. N. Petersen, Z. Pan, S. Lee, S. A. Havstad, and A. E. Willner, “Online chromatic dispersion monitoring and compensation using a single inband subcarrier tone,” *IEEE Photonics Technol. Lett.*, vol. 14, no. 4, pp. 570–572, Apr. 2002, doi: 10.1109/68.992614.
- [23] T. E. Dimmick, G. Rossi, and D. J. Blumenthal, “Optical dispersion monitoring technique using double sideband subcarriers,” *IEEE Photonics Technol. Lett.*, vol. 12, no. 7, pp. 900–902, Jul. 2000, doi: 10.1109/68.853544.
- [24] B. Kozicki, O. Takuya, and T. Hidehiko, “Optical performance monitoring of phase-modulated signals using asynchronous amplitude histogram analysis,” *J. Light. Technol.*, vol. 26, no. 10, pp. 1353–1361, May 2008, doi: 10.1109/JLT.2008.917374.
- [25] L. Zhihong and L. Guifang, “In-service monitoring of chromatic dispersion and polarization mode dispersion for RZ-DPSK signal based on asynchronous amplitude histogram evaluation,” *2006 Opt. Fiber Commun. Conf. 2006 Natl. Fiber Opt. Eng. Conf.*, vol. 2006, 2006, doi: 10.1109/OFC.2006.215583.
- [26] Z. Li and G. Li, “In-line performance monitoring for RZ-DPSK signals using asynchronous amplitude histogram evaluation,” *IEEE Photonics Technol. Lett.*, vol. 18, no. 3, pp. 472–474, Feb. 2006, doi: 10.1109/LPT.2005.861968.
- [27] J. Zhao, C. Lu, and H. Y. Tam, “Nonlinear effect on residual dispersion monitoring of DPSK signals using delay-tap sampling and Hausdorff distance measure,” 2009, doi: 10.1109/OECC.2009.5214288.

- [28] J. Siuzdak, *Wstęp do współczesnej telekomunikacji światłowodowej*, WKiŁ, 1999.
- [29] V. Ribeiro, M. Lima, and A. Teixeira, “Parametric asynchronous eye diagram for optical performance monitoring,” 2012, doi: 10.1364/nfoec.2012.jw2a.33.
- [30] A. L. J. Teixeira, L. Costa, M. Lima, and V. Ribeiro, “Optical performance monitoring using the novel parametric asynchronous eye diagram,” *Opt. Express*, Vol. 20, Issue 9, pp. 9851-9861, vol. 20, no. 9, pp. 9851–9861, Apr. 2012, doi: 10.1364/OE.20.009851.
- [31] M. Li and J. Yao, “Multichannel arbitrary-order photonic temporal differentiator for wavelength-division-multiplexed signal processing using a single fiber Bragg grating,” *J. Light. Technol.*, vol. 29, no. 17, pp. 2506–2511, 2011, doi: 10.1109/JLT.2011.2159827.
- [32] J. Azaña and M. Kulishov, “Long-period fiber gratings as ultrafast optical differentiators,” *Opt. Lett. Vol. 30, Issue 20*, pp. 2700-2702, vol. 30, no. 20, pp. 2700–2702, Oct. 2005, doi: 10.1364/OL.30.002700.
- [33] M. Westlund, H. Sunnerud, M. Karlsson, and P. A. Andrekson, “Software-synchronized all-optical sampling for fiber communication systems,” *J. Light. Technol.*, vol. 23, no. 3, pp. 1088–1099, Mar. 2005, doi: 10.1109/JLT.2004.838875.
- [34] A. Yang, J. Lai, and Y. N. Sun, “A chirp-z-transform-based software synchronization method for optical performance monitoring,” *IEEE Photonics Technol. Lett.*, vol. 23, no. 22, pp. 1739–1741, 2011, doi: 10.1109/LPT.2011.2167746.
- [35] L. R. Rabiner and R. W. Schafer, “The Chirp z-Transform Algorithm,” *IEEE Trans. Audio Electroacoust.*, vol. 17, no. 2, pp. 86–92, 1969, doi: 10.1109/TAU.1969.1162034.
- [36] J. Lai, A. Yang, and Y. Sun, “Multiple-impairment monitoring for 40-Gbps RZ-OOK using artificial neural networks trained with reconstructed eye diagram parameters,” *Opt. InfoBase Conf. Pap.*, vol. 1, no. September, pp. 563–565, 2011.
- [37] X. Wu, J. A. Jargon, R. A. Skoog, L. Paraschis, and A. E. Willner, “Applications of artificial neural networks in optical performance monitoring,” *J. Light. Technol.*, vol. 27, no. 16, pp. 3580–3589, Aug. 2009, doi: 10.1109/JLT.2009.2024435.
- [38] C. Lu, D. Liu, H. Y. Tam, J. Zhao, L. Cheng, and Z. Li, “NRZ-DPSK and RZ-DPSK Signals Signed Chromatic Dispersion Monitoring Using Asynchronous Delay-Tap Sampling,” *J. Light. Technol. Vol. 27, Issue 23*, pp. 5295-5301, vol. 27, no. 23, pp. 5295–5301, Dec. 2009, Accessed: Oct. 25, 2020. [Online]. Available: <https://www.osapublishing.org/abstract.cfm?uri=jlt-27-23-5295>.

- [39] S. D. Dods and T. B. Anderson, "Optical performance monitoring technique using delay tap asynchronous waveform sampling," in *2006 Optical Fiber Communication Conference, and the 2006 National Fiber Optic Engineers Conference*, 2006, vol. 2006, doi: 10.1109/ofc.2006.215890.
- [40] A. Kowalczyk, D. Hewitt, J. C. Li, K. Clarke, S. D. Dods, and T. B. Anderson, "Multi Impairment Monitoring for Optical Networks," *J. Light. Technol. Vol. 27, Issue 16*, pp. 3729-3736, vol. 27, no. 16, pp. 3729–3736, Aug. 2009, Accessed: Oct. 25, 2020. [Online]. Available: <https://www.osapublishing.org/abstract.cfm?uri=jlt-27-16-3729>.
- [41] "VPIphotonics: Simulation Software and Design Services." <https://www.vpiphotonics.com/index.php> (accessed Aug. 09, 2021).
- [42] T. Anderson *et al.*, "Demonstration of Simultaneous OSNR and CD Monitoring using Asynchronous Delay Tap Sampling on an 800 km WDM Test Bed," no. 1. VDM Verlag, pp. 2–3, 2009, Accessed: Oct. 25, 2020. [Online]. Available: <https://research.monash.edu/en/publications/demonstration-of-simultaneous-osnr-and-cd-monitoring-using-asynch>.
- [43] W. S. Noble, "What is a support vector machine?," *Nat. Biotechnol.*, vol. 24, 2006, Accessed: Aug. 07, 2021. [Online]. Available: <http://www.nature.com/naturebiotechnology>.
- [44] H. Y. Choi, Y. Takushima, and Y. C. Chung, "Multiple-impairment monitoring technique using optical field detection and asynchronous delay-tap sampling method," in *Conference on Optical Fiber Communication, Technical Digest Series*, Mar. 2009, p. OThJ5, doi: 10.1364/ofc.2009.othj5.
- [45] B. Guo, K. M. Lam, K. H. Lin, and W. C. Siu, "Human face recognition based on spatially weighted Hausdorff distance," *Pattern Recognit. Lett.*, vol. 24, no. 1–3, pp. 499–507, Jan. 2003, doi: 10.1016/S0167-8655(02)00272-6.
- [46] D. P. Huttenlocher, G. A. Klanderman, and W. J. Rucklidge, "Comparing Images Using the Hausdorff Distance," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, no. 9, pp. 850–863, 1993, doi: 10.1109/34.232073.
- [47] J. Zhao, C. Lu, K. M. Lam, Z. Li, H. Y. Tam, and P. K. A. Wai, "A novel optical signal monitoring method of DPSK signal based on delay tap sampling and Hausdorff distance measure," 2008, doi: 10.1109/CLEO.2008.4552261.
- [48] C. M. Bishop, "Neural networks for pattern recognition," p. 482, 1995.
- [49] H. K. D. H. Bhadeshia, "Neural Networks in Materials Science," *ISIJ Int.*, vol. 39, no. 10, pp. 966–979, Oct. 1999, doi: 10.2355/ISIJINTERNATIONAL.39.966.

- [50] M. Egmont-Petersen, D. De Ridder, and H. Handels, "Image processing with neural networks—a review," *Pattern Recognit.*, vol. 35, no. 10, pp. 2279–2301, Oct. 2002, doi: 10.1016/S0031-3203(01)00178-9.
- [51] J. A. Jargon, X. Wu, and A. E. Willner, "Optical performance monitoring by use of artificial neural networks trained with parameters derived from delay-tap asynchronous sampling," *Conf. Opt. Fiber Commun. Tech. Dig. Ser.*, pp. 3–5, 2009, doi: 10.1364/ofc.2009.othh1.
- [52] J. Shawe-Taylor and N. Cristianini, "Kernel Methods for Pattern Analysis," *Kernel Methods Pattern Anal.*, Jun. 2004, doi: 10.1017/CBO9780511809682.
- [53] T. De Bie and N. Cristianini, "Kernel Methods for Exploratory Pattern Analysis: A Demonstration on Text Data," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 3138, pp. 16–29, 2004, doi: 10.1007/978-3-540-27868-9_2.
- [54] B. Kozicki, A. Maruta, and K. Kitayama, "Experimental demonstration of optical performance monitoring for RZ-DPSK signals using delay-tap sampling method," *Opt. Express*, vol. 16, no. 6, p. 3566, Mar. 2008, doi: 10.1364/oe.16.003566.
- [55] J. Illingworth and J. Kittler, "A survey of the hough transform," *Comput. Vision, Graph. Image Process.*, vol. 44, no. 1, pp. 87–116, Oct. 1988, doi: 10.1016/S0734-189X(88)80033-1.
- [56] M. S. Nixon and A. S. Aguado, "Feature Extraction and Image Processing," *Featur. Extr. Image Process.*, 2002, doi: 10.1016/C2009-0-25049-5.
- [57] P. Mukhopadhyay and B. B. Chaudhuri, "A survey of Hough Transform," *Pattern Recognit.*, vol. 48, no. 3, pp. 993–1010, Mar. 2015, doi: 10.1016/J.PATCOG.2014.08.027.
- [58] B. Kozicki, A. Maruta, and K. I. Kitayama, "Transparent performance monitoring of RZ-DQPSK systems employing delay-tap sampling," *J. Opt. Netw.*, vol. 6, no. 11, pp. 1257–1269, Nov. 2007, doi: 10.1364/JON.6.001257.
- [59] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [60] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202, Apr. 1980, doi: 10.1007/BF00344251.

- [61] D. H. Hubel and T. N. Wiesel, “Receptive fields of single neurones in the cat’s striate cortex,” *J. Physiol.*, vol. 148, no. 3, pp. 574–591, Oct. 1959, doi: 10.1113/jphysiol.1959.sp006308.
- [62] W. (1921-). Rudin, P. Sołtan, G. Świrszcz, and T. Świrszcz, “Analiza funkcjonalna,” 2009.
- [63] R. N. (Ronald N. Bracewell, “The Fourier transform and its applications,” p. 616, 2000.
- [64] S. W. Smith, *Digital Signal Processing: A Practical Guide for Engineers and Scientists*, vol. 17, no. 2. Elsevier Science & Technology, 2003.
- [65] W. K. Chen, *The electrical engineering handbook*. Elsevier Academic Press, 2005.
- [66] Y. LeCun, K. Kavukcuoglu, and C. Farabet, “Convolutional networks and applications in vision,” in *ISCAS 2010 - 2010 IEEE International Symposium on Circuits and Systems: Nano-Bio Circuit Fabrics and Systems*, 2010, pp. 253–256, doi: 10.1109/ISCAS.2010.5537907.
- [67] Y. LeCun *et al.*, “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Comput.*, vol. 1, no. 4, pp. 541–551, Dec. 1989, doi: 10.1162/neco.1989.1.4.541.
- [68] Y. Le Cun, “Learning Process in an Asymmetric Threshold Network,” in *Disordered Systems and Biological Organization*, Springer-Verlag, 1986, pp. 233–240.
- [69] K. Fukushima, “Cognitron: A self-organizing multilayered neural network,” *Biol. Cybern.*, vol. 20, no. 3–4, pp. 121–136, Sep. 1975, doi: 10.1007/BF00342633.
- [70] K. Fukushima and S. Miyake, “Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position,” *Pattern Recognit.*, vol. 15, no. 6, pp. 455–469, Jan. 1982, doi: 10.1016/0031-3203(82)90024-3.
- [71] N. H. Goddard, “The perception of multiple objects: A connectionist approach,” *Artif. Intell.*, vol. 62, no. 1, pp. 165–177, 1993, doi: 10.1016/0004-3702(93)90055-g.
- [72] Y. LeCun and others, “Generalization and network design strategies,” in *Connectionism in perspective*, 1989, pp. 143–155, Accessed: Nov. 21, 2021. [Online]. Available: <https://www.academia.edu/download/30766382/lecun.pdf>.
- [73] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning Internal Representations by Error Propagation,” in *Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence*, 2013, pp. 399–421.

- [74] L. D. Le Cun Jackel, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, B. Le Cun, J. Denker, and D. Henderson, “Handwritten Digit Recognition with a Back-Propagation Network,” *Adv. Neural Inf. Process. Syst.*, pp. 396–404, 1990, Accessed: Nov. 22, 2021. [Online]. Available: <http://papers.nips.cc/paper/293-handwritten-digit-recognitionwith-a-back-propagation-network.pdf>.
- [75] G. L. Martin, “Centered-Object Integrated Segmentation and Recognition of Overlapping Handprinted Characters,” *Neural Comput.*, vol. 5, no. 3, pp. 419–429, 1993, doi: 10.1162/neco.1993.5.3.419.
- [76] J. Wang and J. Jean, “Multiresolution neural networks for omnifont character recognition,” *1993 IEEE Int. Conf. Neural Networks*, pp. 1588–1593, 1993, doi: 10.1109/ICNN.1993.298793.
- [77] Y. Bengio, Y. LeCun, C. Nohl, and C. Burges, “LeRec: a NN/HMM hybrid for on-line handwriting recognition.,” *Neural Comput.*, vol. 7, no. 6, pp. 1289–1303, 1995, doi: 10.1162/NECO.1995.7.6.1289.
- [78] S. Lawrence, C. L. Giles, A. C. Tsoi, and A. D. Back, “Face recognition: A convolutional neural-network approach,” *IEEE Trans. Neural Networks*, vol. 8, no. 1, pp. 98–113, 1997, doi: 10.1109/72.554195.
- [79] K. Lang, “A time delay neural network architecture for speech recognition.,” 1990, Accessed: Nov. 22, 2021. [Online]. Available: <https://elibrary.ru/item.asp?id=5913602>.
- [80] A. Waibel, T. Hanazawa, G. Hinton, K. Shikano, and K. J. Lang, “Phoneme Recognition Using Time-Delay Neural Networks,” *IEEE Trans. Acoust.*, vol. 37, no. 3, pp. 328–339, 1989, doi: 10.1109/29.21701.
- [81] L. Bottou, F. Fogelman Soulié, P. Blanchet, and J. S. Liénard, “Speaker-independent isolated digit recognition: Multilayer perceptrons vs. Dynamic time warping,” *Neural Networks*, vol. 3, no. 4, pp. 453–465, 1990, doi: 10.1016/0893-6080(90)90028-J.
- [82] P. Haffner and A. H. Waibel, “Time-Delay Neural Networks Embedding Time Alignment: a Performance Analysis,” 1991, Accessed: Nov. 22, 2021. [Online]. Available: <https://isl.anthropomatik.kit.edu/pdf/Haffner1991.pdf>.
- [83] I. Guyon, P. Albrecht, Y. Le Cun, J. Denker, and W. Hubbard, “Design of a neural network character recognizer for a touch terminal,” *Pattern Recognit.*, vol. 24, no. 2, pp. 105–119, Jan. 1991, doi: 10.1016/0031-3203(91)90081-F.
- [84] J. BROMLEY *et al.*, “SIGNATURE VERIFICATION USING A ‘SIAMESE’ TIME DELAY NEURAL NETWORK,” *Int. J. Pattern Recognit. Artif. Intell.*, vol. 07, no. 04, pp. 669–688, Aug. 1993, doi: 10.1142/s0218001493000339.

- [85] T. Mrozek, K. Perlicki, T. Tajmajer, and P. Wasilewski, "Optical transmission testing based on asynchronous sampling techniques: Images analysis containing chromatic dispersion using convolutional neural network," in *Proceedings of SPIE - The International Society for Optical Engineering*, 2017, vol. 10445, doi: 10.1117/12.2281111.
- [86] J. Zhang *et al.*, "Intelligent adaptive coherent optical receiver based on convolutional neural network and clustering algorithm," *Opt. Express*, vol. 26, no. 14, p. 18684, 2018, doi: 10.1364/oe.26.018684.
- [87] Y. Cheng, S. Fu, M. Tang, and D. Liu, "Multi-task deep neural network (MT-DNN) enabled optical performance monitoring from directly detected PDM-QAM signals," *Opt. Express*, vol. 27, no. 13, p. 19062, 2019, doi: 10.1364/oe.27.019062.
- [88] D. Wang *et al.*, "Intelligent constellation diagram analyzer using convolutional neural network-based deep learning," *Opt. Express*, vol. 25, no. 15, p. 17150, Jul. 2017, doi: 10.1364/oe.25.017150.
- [89] D. Wang *et al.*, "Modulation Format Recognition and OSNR Estimation Using CNN-Based Deep Learning," *IEEE Photonics Technol. Lett.*, vol. 29, no. 19, pp. 1667–1670, 2017, doi: 10.1109/LPT.2017.2742553.
- [90] X. Fan *et al.*, "Feature Fusion-Based Multi-Task ConvNet for Simultaneous Optical Performance Monitoring and Bit-Rate/Modulation Format Identification," *IEEE Access*, vol. 7, pp. 126709–126719, 2019, doi: 10.1109/ACCESS.2019.2939043.
- [91] X. Fan *et al.*, "Joint Optical Performance Monitoring and Modulation Format/Bit-Rate Identification by CNN-Based Multi-Task Learning," *IEEE Photonics J.*, vol. 10, no. 5, 2018, doi: 10.1109/JPHOT.2018.2869972.
- [92] "TensorFlow White Papers." <https://www.tensorflow.org/about/bib> (accessed Oct. 27, 2020).
- [93] Aymeric Damien and others, "TFLearn," *GitHub*, 2016. <https://github.com/tflearn/tflearn> (accessed Jan. 25, 2022).
- [94] T. Mrozek and K. Perlicki, "Simultaneous monitoring of the values of CD, Crosstalk and OSNR phenomena in the physical layer of the optical network using CNN," *Opt. Quantum Electron.*, vol. 53, no. 11, p. 640, Nov. 2021, doi: 10.1007/S11082-021-03280-5.

- [95] T. Mrozek, “Simultaneous Monitoring of Chromatic Dispersion and Optical Signal to Noise Ratio in Optical Network Using Asynchronous Delay Tap Sampling and Convolutional Neural Network (Deep Learning),” in *International Conference on Transparent Optical Networks*, 2018, vol. 2018-July, doi: 10.1109/ICTON.2018.8473703.
- [96] T. Mrozek and K. Perlicki, “Comprehensive analysis of the ability to monitor selected optical network parameters in the physical layer using convolutional neural networks,” in *Proceedings of SPIE - The International Society for Optical Engineering*, 2018, vol. 10808, doi: 10.1117/12.2501464.
- [97] T. Mrozek and K. Perlicki, “Simultaneous monitoring of the phenomena of CD, Crosstalk, and OSNR in the physical layer of the optical network with the use of convolutional neural networks,” in *Proceedings of SPIE - The International Society for Optical Engineering*, 2019, vol. 11176, doi: 10.1117/12.2539011.
- [98] T. Mrozek, K. Perlicki, and A. Jakubiak, “Simultaneous monitoring of chromatic dispersion and optical signal to noise ratio in optical links using convolutional neural network and asynchronous delay-tap sampling,” *Opt. Appl.*, vol. 50, no. 3, pp. 331–341, 2020, doi: 10.37190/OA200301.

Wykaz rysunków

Rys. 3.1 Wykres oczkowy z zaznaczonymi mierzalnymi parametrami.....	27
Rys. 3.2 Maska oka [21].	28
Rys. 3.3 Sposób dodania tonu do pasma sygnału na jego podnośnej.	29
Rys. 3.4 Sposób zanikania tonu w wyniku oddziaływania dyspersji chromatycznej [19].	30
Rys. 3.5 Generowanie próbek sygnału fali optycznej wykorzystanych do budowy histogramu.	31
Rys. 3.6 Przykładowy histogram prezentowanej metody dla sygnału RZ-DPSK [24].	31
Rys. 3.7 Wykresy przedstawiające wpływ poszczególnych zjawisk na kształt wykresów [29].	33
Rys. 3.8 Wykres przedstawiający rekonstrukcje sygnału, a) sygnał uzyskany w fotodetektorze i po spróbkowaniu, b) zastosowanie algorytmu CZT-SS, c) uzyskany zrekonstruowany wykres oka [36].	34
Rys. 3.9 Przykładowe zrekonstruowane wykresy oka, z różnymi wartościami zakłóceń [36].	34
Rys. 3.10 Wpływ różnych zjawisk na kształt wykresów punktowych dla prędkości transmisji 40 Gbit/s, formatu modulacji NRZ-DPSK i opóźnienia 1 bit [13].	35
Rys. 3.11 Schemat ideowy metody ADTS z wyszczególnieniem okna z przykładowym próbkowaniem asynchronicznym.....	36
Rys. 3.12 Przykładowe niezakłócone portrety fazy dla wybranych modulacji i opóźnień bitowych.	36
Rys. 3.13 Zasada przekształcenia Hougha.....	41
Rys. 4.1 Standardowa architektura sieci spłotowej Le-Net5 wprowadzona przez Yanna LeCuna.	48
Rys. 4.2 Wykres funkcji aktywacji ReLU. Funkcję ReLU można przedstawić następująco $f(x) = \{0 \text{ dla } x < 0; x \text{ dla } \geq x 0\}$	49
Rys. 4.3 Prezentacja działania filtru (2x2) na przykładzie dwóch podejść obliczeniowych, a) operacja Max Pooling, b) Average Pooling.	50
Rys. 4.4 Architektura sieci spłotowej LeNet-5 [59].	51
Rys. 4.5 Operacja spłotu na obrazie wejściowym o rozmiarze 32x32 pikseli w wyniku której powstaje mapa cech (warstwa C1) o rozmiarze 28x28 pikseli. Spłot został przeprowadzony z wykorzystaniem pola receptywnego o rozmiarze 5x5 pikseli. W trakcie tej operacji	

wykonywanych jest 784 przejść (po 28 dla każdej kolumny i wiersza) z równym krokiem 1. Kolorami zaznaczono przykładowe przejście pola receptywnego przez obraz wejściowy i odpowiadające im obliczone wartości dla mapy cech. Analogiczna procedura wykonywana jest na macierzy <i>S2</i> i w rezultacie daje macierz <i>C3</i>	53
Rys. 4.6 Przykład operacji próbkowania zmniejszającej rozmiar mapy cech, warstwy <i>C1</i> z 28x28 pikseli do 14x14 pikseli (warstwa <i>S2</i>), z wykorzystaniem pola receptywnego o rozmiarze 2x2. Analogiczna procedura wykonywana jest na macierzy <i>C3</i> i w rezultacie daje macierz <i>S4</i>	54
Rys. 5.1 Schemat metody ADTS w środowisku VPIphotonics dla modulacji OOK.	61
Rys. 5.2 Architektura zbudowanej splotowej sieci neuronowej.	63
Rys. 6.1 Układ monitorujący zjawiska dyspersji chromatycznej, przeniku wewnątrzkanałowego oraz szumu ASE.	108

Wykaz tabel

Tabela 2.1 Poziomy dokładności monitorowania wymagane przez OPM dla wybranych parametrów.....	20
Tabela 3.1 Kształt portretu fazy dla zjawisk dyspersji chromatycznej, przeniku i szumu ASE dla modulacji OOK i opóźnienia 1 bit.....	37
Tabela 3.2 Przykładowe portrety fazy dla różnych modulacji oraz opóźnień bitowych.....	38
Tabela 3.3 Porównanie technik do wyznaczania wartości liczbowych z metody ADTS.	42
Tabela 5.1 Ustawienia przyjęte w trakcie procesu uczenia sieci spłotowej.....	64
Tabela 5.2 Kolejność przeprowadzenia procesu uczenia spłotowej sieci neuronowej.	66
Tabela 5.3 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.	67
Tabela 5.4 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.....	68
Tabela 5.5 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.	69
Tabela 5.6 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.....	70
Tabela 5.7 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,25 bit.	71
Tabela 5.8 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,25 bit.....	72
Tabela 5.9 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.	73

Tabela 5.10 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.....	74
Tabela 5.11 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.	75
Tabela 5.12 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.....	76
Tabela 5.13 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 0,5 bit.	77
Tabela 5.14 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 0,5 bit.....	78
Tabela 5.15 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.	79
Tabela 5.16 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości dyspersji chromatycznej uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.....	80
Tabela 5.17 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.	81
Tabela 5.18 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości przeniku optycznego uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.....	82
Tabela 5.19 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji DPSK oraz opóźnienia 1 bit.	83
Tabela 5.20 Współczynniki dopasowania modeli $R2$ oraz średnie wartości błędu wyznaczania wartości OSNR uzyskane w trakcie procesu uczenia spłotowej sieci neuronowej dla modulacji OOK oraz opóźnienia 1 bit.....	84

Tabela 5.21 Podsumowanie najniższych średnich wartości błędów dyspersji chromatycznej oraz współczynników dopasowania R_2 uzyskanych w procesie uczenia sieci; CD – dyspersja chromatyczna.....	85
Tabela 5.22 Podsumowanie najniższych średnich wartości błędów przeniku oraz współczynników dopasowania R_2 uzyskanych w procesie uczenia sieci.....	86
Tabela 5.23 Podsumowanie najniższych średnich wartości błędów OSNR oraz współczynników dopasowania R_2 uzyskanych w procesie uczenia sieci; OSNR – Optyczny stosunek sygnał-szum.....	86
Tabela 6.1 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,25 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	90
Tabela 6.2 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 0,25 bitu.	91
Tabela 6.3 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,25 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	92
Tabela 6.4 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnienia 0,25 bit.	93
Tabela 6.5 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 0,5 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	94
Tabela 6.6 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 0,5 bit..	95
Tabela 6.7 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 0,5 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	96
Tabela 6.8 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnienia 0,5 bit. ..	97
Tabela 6.9 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji DPSK i opóźnienia 1 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	98
Tabela 6.10 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji DPSK i opóźnienia 1 bit.....	99

Tabela 6.11 Wyznaczanie wartości parametrów opisujących równocześnie występujące zjawiska dla modulacji OOK i opóźnienia 1 bit. Zamieszczone w tabeli wyniki wyrażone są w procentach.	100
Tabela 6.12 Przykładowe portrety fazy uzyskane w trakcie procesu wyznaczania wartości parametrów opisujących monitorowane zjawiska dla modulacji OOK i opóźnienia 1 bit. ...	101
Tabela 6.13 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 0,25 bit dla modulacji DPSK i OOK.	102
Tabela 6.14 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 0,5 bit dla modulacji DPSK i OOK.	103
Tabela 6.15 Porównanie najlepszych wyników uzyskanych dla poszczególnych zestawów w procesie wyznaczania wartości parametrów opisujących monitorowane zjawiska dla opóźnienia 1 bit oraz modulacji DPSK i OOK.	104
Tabela 6.16 Porównanie wyników otrzymanych w ramach pracy doktorskiej z wynikami istniejącymi.	107