

**POLITECHNIKA KRAKOWSKA**  
WYDZIAŁ INŻYNIERII LĄDOWEJ  
INSTYTUT MECHANIKI BUDOWLI

Prognozowanie przekazywania drgań pochodzenia  
górniczego z gruntu na budynek z wykorzystaniem SSN

ROZPRAWA DOKTORSKA  
mgr inż. Łukasz Chudyba

Promotor

dr hab. inż. Krystyna Kuźniar, prof. UP

KRAKÓW 2013



*dr hab. inż. Krystynie Kuźniar prof. UP serdecznie dziękuję  
za trud, wnikliwą recenzję oraz cenne uwagi*



*Omedze - serdeczne podziękowania za inspiracje*



## Spis treści

1.	WSTĘP.....	4
1.1.	Geneza i opis problemu.....	4
1.2.	Cel, zakres i tezy naukowe pracy.....	6
1.2.1.	Cel i zakres pracy.....	6
1.2.2.	Tezy naukowe pracy.....	7
1.3.	Przegląd aktualnego stanu wiedzy.....	8
2.	ANALIZA WYNIKÓW BADAŃ DOŚWIADCZALNYCH.....	11
2.1.	Uwagi wstępne.....	11
2.2.	Analiza różnic w jednocześnie zarejestrowanych drganiach gruntu obok budynku i fundamentu budynku.....	16
2.3.	Ocena przekazywania drgań z podłoża na budynek.....	26
2.3.1.	Wstęp.....	26
2.3.2.	Wpływ energii wstrząsów górniczych $E_n$ na przekazywanie drgań z gruntu na fundament budynku.....	28
2.3.3.	Wpływ odległości epicentralnej $r_e$ na przekazywanie drgań z gruntu na fundament budynku.....	31
2.3.4.	Wpływ kierunku dotarcia fali na przekazywanie drgań z gruntu na fundament budynku.....	34
2.3.5.	Wpływ maksymalnych wartości (amplitud) drgań gruntu na przekazywanie drgań z gruntu na fundament budynku.....	40
2.3.6.	Wpływ dominujących częstotliwości drgań gruntu na przekazywanie drgań z gruntu na fundament budynku.....	43
2.3.7.	Podsumowanie.....	44
3.	WYBRANE ZAGADNIENIA TEORII SZTUCZNYCH SIECI NEURONOWYCH (SSN).....	48
3.1.	Wiadomości wstępne.....	48
3.2.	Zastosowane sztuczne sieci neuronowe.....	52
3.2.1.	Sieci neuronowe typu wstecznej propagacji błędu (WPB).....	52
3.2.2.	Sztuczne sieci neuronowe z regularyzacją.....	53
3.2.3.	Bayesowskie sieci neuronowe.....	54
3.2.4.	Kaskadowe sztuczne sieci neuronowe.....	55
4.	NEURONOWE PROGNOZOWANIE PRZKAZYWANIA DRGAŃ OD WSTRZĄSÓW GÓRNICZYCH Z PODŁOŻA NA FUNDAMENT BUDYNKU.....	57
4.1.	Uwagi wstępne.....	57
4.2.	Wyniki obliczeń z użyciem standardowych sztucznych sieci neuronowych typu WPB.....	62
4.2.1.	Analiza przekazywania składowych przyspieszeń drgań.....	62



4.2.2.	Analiza przekazywania wypadkowych przyspieszeń drgań.....	70
4.2.3.	Analiza przekazywania składowych prędkości drgań.....	74
4.2.4.	Analiza przekazywania wypadkowych prędkości drgań.....	80
4.3.	Wyniki obliczeń z użyciem sieci neuronowych z regularyzacją oraz bayesowskich sieci neuronowych .....	84
4.4.	Propozycja zastosowania kaskadowych sieci neuronowych .....	90
4.5.	Wnioski .....	94
5.	PROPOZYCJE WZORÓW EMPIRYCZNYCH DO OCENY PRZEKAZYWANIA DRGAŃ Z PODŁOŻA NA BUDYNEK.....	100
5.1.	Modele regresji wielokrotnej.....	100
5.2.	Wyniki obliczeń za pomocą wzorów empirycznych.....	101
6.	WNIOSKI I UWAGI KOŃCOWE .....	108
7.	PROPOZYCJE KIERUNKÓW DALSZYCH BADAŃ ZWIĄZANYCH Z TEMATEM.....	112
	LITERATURA.....	113
	SPIS RYSUNKÓW .....	121
	SPIS TABEL .....	127

# 1. WSTĘP

## 1.1. Geneza i opis problemu

Wśród wielu oddziaływań dynamicznych na budowlę, do szczególnie istotnych należą obciążenia sejsmiczne i parasejsmiczne. Te pierwsze są spowodowane trzęsieniami ziemi, natomiast te drugie wynikają z działalności człowieka (np. tąpnięcia w kopalniach, wstrząsy górnicze, komunikacja pojazdów drogowych lub szynowych, wbijanie pali).

W trakcie przekazywania drgań z gruntu na obiekt występuje zjawisko wzajemnego oddziaływania (współpracy) układu konstrukcja-podłoże, nazywane interakcją dynamiczną. W zagadnieniu interakcji dynamicznej grunt-budynek należy wyróżnić dwa aspekty, które odgrywają znaczącą rolę w inżynierii sejsmicznej i parasejsmicznej. Odpowiedź budynku posadowionego na odkształcalnym podłożu na działanie sejsmiczne może się różnić od tej jaką może mieć budynek na sztywnym podłożu. Poza tym ruch zarejestrowany w bezpośrednim jego sąsiedztwie może być różny od tego jaki mógłby być zarejestrowany w przypadku braku budynku. Zatem w zjawisku interakcji występuje wyraźne sprzężenie zachowania się budynku i gruntu. Z inżynierskiego punktu widzenia jest to bardzo ważne zagadnienie, chodzi bowiem o prognozowanie wpływu drgań na budynek, jak również o analizę sposobu tego przenoszenia. Sejsmolodzy, w szczególności sejsmolodzy górniczy, zajmujący się drganiami gruntu, zalecają uwzględnienie drgań gruntu w przypadku oceny ich szkodliwości dla budynków. Jednak jednocześnie rejestrowane przebiegi drgań fundamentów budynków i gruntu w ich pobliżu mogą wykazywać istotne różnice [42, 43, 46, 50, 54]. Tymczasem dokładniejsza ocena szkodliwości drgań dla budynków jest możliwa na podstawie drgań ich fundamentów [49]. Zatem wtedy, gdy pomiarów drgań dokonuje się tylko na gruncie (co jest częstym przypadkiem w praktyce), potrzebne jest na ich podstawie prognozowanie drgań fundamentów budynków [42, 46].

Problem niejednoznacznego przekazywania się drgań z gruntu na fundament budynku oraz trudności z oceną sposobu tego przekazywania, a więc interakcji dynamicznej wielokrotnie stwierdzono w pracach dotyczących wpływu drgań na różnego rodzaju konstrukcje [33, 42 - 44, 46 - 50, 53, 54, 64, 75, 82 - 84].

W niniejszej pracy uwagę skupiono na wstrząsach górniczych, które powstają na skutek wydobywania rudy miedzi, powodującego pękanie skał nad wyrobiskami górniczymi. Na skutek zachwiania stanu równowagi skał, zjawisko to występuje samoczynnie. W wyniku wybrania części złoża i wydobywania skał leżących nad wyrobiskiem, wzajemna równowaga między składowymi naprężeniami w górotworze zostaje zachwiana. W takim stanie akumulowana jest energia sprężysta, a stan ten nie utrzymuje się długo ze względu na naturalny proces dążenia skał do odzyskania utraconej równowagi. W przypadku twardych, trudno urabialnych skał

nadkładowych zjawisko to przebiega gwałtownie i wydzielane są duże ilości energii, które poprzez propagowanie się fal na powierzchnię negatywnie wpływają na okoliczną zabudowę, powodując jej drgania. Wstrząsy te zaliczane są do zjawisk parasejsmicznych ponieważ są ściśle związane z działalnością człowieka. Niemniej jednak, zjawiska te zbliżone są do trzęsień ziemi o niewielkiej intensywności (również występują losowo i nie są kontrolowane przez człowieka) – magnitudy w przedziale 3,5 - 4,5. Pewnym ułatwieniem w stosunku do analizy trzęsień ziemi jest to, że wstrząsy górnicze pojawiają się w znanych, przewidywanych strefach – regionach górniczych [17].

W Polsce obszarami szczególnie narażonymi na wystąpienie drgań powierzchni ziemi są tereny aktywności górniczej. Najwięcej prac, co oczywiste, dotyczy wpływu tych wstrząsów na budynki mieszkalne. Takie wstrząsy górnicze generowane są poprzez wydobywanie rudy miedzi w Legnicko – Głogowskim Okręgu Miedziowym (LGOM). Eksploatacja górnicza w LGOM prowadzona jest od kilkudziesięciu lat. W związku z coraz głębszą eksploatacją (1000 m poniżej terenu), twardych skał nadkładowych (wapienno – dolomitowych i anhydrytów), w ostatnich latach sejsmiczność w rejonie LGOM wyraźnie wzrosła [49, 64, 82, 99]. Najlepszym sposobem określenia oddziaływania wstrząsów górniczych na konstrukcje budowlane jest zarejestrowanie rzeczywistych przebiegów drgań w wybranych punktach na gruncie oraz w budynku. LGOM jest regionem, który w ostatnich latach poddany jest ciągłemu monitoringowi, a przebiegi drgań powierzchniowych są rejestrowane w stacjach sejsmicznych.

Skala zjawiska oraz wielokrotnie opisywany w literaturze problem niejednoznacznego przekazywania drgań z gruntu na fundament budynku oraz trudności z oceną tego przekazywania, zmusza do konieczności poszukiwania skutecznego narzędzia do prognozowania tego zjawiska. Takim narzędziem mogą być sztuczne sieci neuronowe różnego typu, które umożliwią prognozowanie przekazywania drgań z gruntu na fundament. Sieci neuronowe mogą być stosowane wszędzie tam, gdzie pojawiają się problemy związane z przetwarzaniem i analizą danych, z ich predykcją, klasyfikacją czy sterowaniem. Zasada działania sieci neuronowych różni się od klasycznych metod, gdzie z reguły za pomocą znanych narzędzi i schematów, poszukuje się rozwiązania zadanego problemu. Sieci neuronowe wykorzystują inne podejście. Początkowo konstruowany jest algorytm, który następnie zapisywany jest w postaci programu. Poszukiwanie rozwiązania odbywa się w procesie uczenia, polegającego na podawaniu sieci neuronowej danych wejściowych oraz analizie reakcji sieci neuronowej na te dane. Następnie po etapie uczenia i weryfikacji, można wykorzystywać ją do rozwiązywania postawionego zagadnienia [80].

Podjęto próbę prognozowania przekazywania drgań z podłoża na budynek za pomocą standardowych sztucznych sieci neuronowych, bayesowskich sieci neuronowych, sztucznych sieci neuronowych z regularyzacją oraz kaskadowych sieci neuronowych. Dodatkowo zdecydowano się również na zastosowanie wzorów empirycznych opartych na regresji wielokrotnej, które umożliwiłyby w łatwy i szybki sposób prognozowanie przekazywania

drgań z wystarczającą dokładnością. Problem dotyczy typowego budynku mieszkalnego, reprezentatywnego dla szerokiej grupy budynków o średniej wysokości, podobnej konstrukcji ścianowej (z prefabrykowanych płyt), a tym samym podobnych właściwościach dynamicznych.

## **1.2. Cel, zakres i tezy naukowe pracy**

### **1.2.1. Cel i zakres pracy**

Zasadniczym celem pracy jest:

- analiza wyników badań doświadczalnych przekazywania poziomych drgań od wstrząsów górniczych w Legnicko-Głogowskim Okręgu Miedziowym z gruntu na budynek mieszkalny o średniej wysokości w zakresie przyspieszeń oraz prędkości drgań (zarówno wypadkowych, jak i składowych w kierunkach równoległych do osi poprzecznej i podłużnej budynku);
- ocena wpływu parametrów wstrząsów górniczych i drgań gruntu obok budynku na przekazywanie drgań pochodzenia górniczego z gruntu na budynek;
- wykorzystanie wyników badań eksperymentalnych do zaprojektowania sieci neuronowych (różnych typów), za pomocą których możliwe będzie prognozowanie przekazywania drgań z gruntu na budynek i ocena ich przydatności;
- wykorzystanie sieci neuronowych do oceny istotności wpływu wybranych parametrów wstrząsów górniczych i drgań gruntu na dokładność prognozowania przekazywania drgań z gruntu na fundament budynku;
- opracowanie różnych wariantów wzorów empirycznych do oceny przekazywania drgań z gruntu na fundament budynku.

Praca składa się z siedmiu rozdziałów. W rozdziale 1 podano genezę, cel, zakres oraz tezy naukowe pracy. Dokonano również przeglądu wiedzy dotyczącej tematyki niniejszej pracy. W rozdziale 2 przedstawiono analizę wyników badań doświadczalnych w zakresie różnic w jednocześnie zarejestrowanych drganiach gruntu obok budynku oraz fundamentu. Przekazywanie drgań z podłoża na budynek oceniano poprzez porównywanie maksymalnych wartości przyspieszeń oraz prędkości drgań gruntu oraz drgań fundamentu budynku. Badano

wpływ poszczególnych parametrów wstrząsów górniczych (energia wstrząsu, odległość epicentralna, współrzędne sejsmologiczne) oraz parametrów wywołanych przez nie drgań gruntu obok budynku (maksymalne amplitudy przyspieszeń albo prędkości drgań gruntu, dominujące częstotliwości drgań) na to przekazywanie. Analizowano różnice w przekazywaniu drgań z podłoża na budynek w przypadku prędkości i przyspieszeń drgań od tych samych wstrząsów górniczych. W rozdziale 3 omówiono różne typy sztucznych sieci neuronowych zastosowane w niniejszej pracy. Są to: standardowe sztuczne sieci neuronowe (SSN), sieci neuronowe z regularyzacją (SSN + reg.), Bayesowskie sieci neuronowe (BSN) oraz kaskadowe sztuczne sieci neuronowe (KSN). W rozdziale 4 pokazano wyniki prognozowania przekazywania drgań z gruntu na fundament budynku z zastosowaniem zaproponowanych sieci neuronowych z różnymi wariantami wektora wejścia. Technikę neuronową wykorzystano do przewidywania przekazywania drgań z podłoża na budynek: w przypadku składowych przyspieszeń drgań poziomych, składowych prędkości drgań poziomych oraz wypadkowych przyspieszeń drgań poziomych, wypadkowych prędkości drgań poziomych. Analizowano dokładność aproksymacji neuronowej z użyciem poszczególnych sieci neuronowych. W rozdziale 5 przedstawiono próbę zastosowania modeli regresji wielokrotnej (liniowej oraz wykładniczej) do prognozowania przekazywania drgań z gruntu na fundament budynku w przypadku przyspieszeń oraz prędkości drgań poziomych. Rezultaty uzyskane za pomocą zaproponowanych wzorów empirycznych porównano z wynikami otrzymanymi z aproksymacji neuronowej. W rozdziale 6 sformułowano wnioski i uwagi końcowe oparte na wynikach badań doświadczalnych wykonanych w skali naturalnej oraz wynikach obliczeń z zastosowaniem sztucznych sieci neuronowych oraz modeli regresji wielokrotnej, zawartych we wcześniejszych rozdziałach pracy. W rozdziale 7 przedstawiono propozycje kierunków dalszych badań związanych z tematem niniejszej pracy.

### **1.2.2. Tezy naukowe pracy**

- Parametry wstrząsów górniczych (energia wstrząsu, odległość epicentralna, współrzędne sejsmologiczne) oraz parametry wywołanych przez nie drgań gruntu obok budynku (np. amplituda, dominujące częstotliwości) mogą mieć istotny wpływ na przekazywanie drgań z gruntu na budynek.
- Sztuczne sieci neuronowe zaprojektowane i zweryfikowane na bazie danych eksperymentalnych mogą być wygodnym, o satysfakcjonującej dokładności narzędziem do prognozowania przekazywania drgań z gruntu na budynek w przypadku wstrząsów pochodzenia górniczego.

- Wzory empiryczne mogą mieć praktyczne zastosowanie do szybkiej, przybliżonej oceny przekazywania drgań z gruntu na fundament budynku.

### 1.3. Przegląd aktualnego stanu wiedzy

Problem przekazywania drgań typu sejsmicznego lub parasejsmicznego z podłoża na budynek jest ściśle związany ze zjawiskiem współdziałania układu grunt – budynek, a więc interakcji dynamicznej. Badania dotyczące tego zagadnienia mają charakter zarówno eksperymentalny jak i teoretyczny z użyciem różnych metod.

Przez długi okres w inżynierii sejsmicznej zakładano brak sprzężenia w układzie budynek podłoże. Kiedy badano drgania budynków, przyjmowano, że nie mają one wpływu na ruch podłoża. Nie brano też pod uwagę różnic między przebiegami drgań sejsmicznych pomierzonymi na swobodnej powierzchni podłoża w sąsiedztwie budynku i na fundamencie budynku [50]. Housner [27] jako pierwszy zajął się analizą różnic między przebiegami drgań sejsmicznych pomierzonymi na swobodnej powierzchni podłoża obok budynku oraz na fundamencie budynku posadowionego na podatnym podłożu.

W wielu pracach podjęto próbę oceny zmian właściwości dynamicznych i odpowiedzi budynków w zależności od podatności podłoża, na którym budynki te są posadowione, uwzględniając współdziałanie układu budynek – podłoże gruntowe. Prace te można podzielić na takie, gdzie użyto metod teoretycznych oraz prace gdzie wykorzystano badania doświadczalne. Zdecydowana większość współczesnych prac na ten temat ma charakter teoretyczny. Pojawiają się w nich różne modele matematyczne mające opisać to współdziałanie [4, 6, 25, 66, 72, 94, 96, 97].

W modelowaniu komputerowym zjawiska interakcji dynamicznej podłoże – budynek używane są m. in.: metoda elementów skończonych i metoda elementów brzegowych [15, 18, 21, 69, 93], modele typu sprężyna-tłumik-masa [2, 45, 70, 71, 92], analiza częstotliwościowa [25], podejście stochastyczne [68].

Złożone cechy podłoża gruntowego, kształt i wymiary fundamentów analizowanego budynku, charakter oddziaływań sejsmicznych oraz parasejsmicznych powodują, iż zjawisko interakcji jest wyjątkowo złożone i konieczne jest przyjmowanie uproszczających założeń. W pracy [46] dokonano przeglądu szeregu różnych wyidealizowanych modeli konstrukcji, które chociaż różnią się w istotnych szczegółach, można podzielić na dwie kategorie:

- a) takie, które do badania dynamicznej odpowiedzi układów budynek – podłoże przyjmują ruch podłoża jako ustalony,
- b) takie, które do badania odpowiedzi układu przyjmują dowolny, z reguły poziomy ruch podłoża reprezentowany bądź przez zarejestrowane akcelerogramy i sejsmogramy rzeczywistych trzęsień ziemi, bądź przez symulowane ruchy podłoża przypominające drgania sejsmiczne.



Metody obliczeniowe omówione w pracy [46] są najczęściej stosowanymi w badaniach interakcji układu grunt – budynek. Przyjmowano w nich różne założenia upraszczające:

- a) podłoże gruntowe stanowi izotropową, liniową półprzestrzeń sprężystą,
- b) własności podłoża nie zmieniają się podczas drgań,
- c) brak poślizgu pomiędzy podstawą fundamentu, a podłożem,
- d) fundament budynku umiejscowiony jest na powierzchni podłoża,
- e) fundament budynku ma kształt cylindra, kołowa płyta fundamentu jest sztywna,
- f) fale sejsmiczne dochodzą do fundamentu pionowo z głębi ziemi,
- g) fale sejsmiczne powodują tylko poziome ruchy swobodnej powierzchni podłoża.

W pracach [28 - 31, 44, 48, 83, 84] podjęto próbę uwzględnienia interakcji dynamicznej grunt – budynek za pomocą metod doświadczalnych.

W pracy [48] wyznaczono doświadczalnie w skali naturalnej cechy dynamiczne trzech identycznych pięciokondygnacyjnych budynków posadowionych na różnych podłożach. Prace japońskie [28, 29] dotyczą analogicznych zagadnień w odniesieniu do budynków niskich o trzech kondygnacjach, natomiast publikacje [30, 31] budynków czterokondygnacyjnych.

W pracy [44] przedstawiono wyniki badań doświadczalnych 9 – kondygnacyjnego żelbetowego budynku Biblioteki Millikan. Uzyskane rezultaty wykazały, że interakcja ma istotny wpływ na odpowiedź całego budynku na zadane wymuszenia. Stwierdzono, iż translacja i rotacja fundamentu związana z podatnością podłoża prowadzi do ruchu sztywnego części nadziemnej i może stanowić znaczącą część całej odpowiedzi. W pracach [83, 84] przedstawiono badania interakcji grunt – podłoże wykonane w skali naturalnej dotyczące budynku magazynu.

Wiele prac doświadczalnych i obliczeniowych związanych z oceną interakcji grunt – podłoże w przypadku drgań parasejsmicznych powstało w Instytucie Mechaniki Budowli Politechniki Krakowskiej. Do tych prac należy zaliczyć m. in. [33, 42, 43, 47 - 50, 53, 54, 64, 75, 82]. Często proponowany w literaturze sposób oceny przekazywania drgań z gruntu na fundament przez porównanie maksymalnych wartości (amplitud) jednocześnie zarejestrowanych przyspieszeń, prędkości lub przemieszczeń drgań dolnej części budynku i gruntu obok budynku został wykorzystany m. in. w pracy [13] do wyznaczenia współczynnika amplitudalnej redukcji dla drgań wzbudzanych przejazdami pojazdów samochodowych, w pracy [75] do wyznaczenia tzw. współczynnika przeniesienia w przypadku drgań wywoływanych eksploatacją metra, w pracy [74] w odniesieniu do drgań od wbijania pali fundamentowych, a w pracy [82] w przypadku drgań wzbudzanych wstrząsami górnymi.

Intensywny rozwój budownictwa komunikacyjnego (kolej, tramwaj, metro) generuje problemy związane z wpływem drgań na budynki. Takie zagadnienie szczegółowo omówiono m.in. w pracach [34, 35, 76 - 79].

W ostatnich latach wzrosło zainteresowanie narzędziami opartymi na technice neuronowej. Sztuczne sieci neuronowe stają się komplementarnym uzupełnieniem cyfrowych systemów sekwencyjnych. Sieci neuronowe są stosowane w momencie, gdy obliczenia sekwencyjne są mało efektywne lub niemożliwe do zastosowania. Teorię sztucznych sieci neuronowych przedstawiono m. in. w pracach [22, 36, 57, 62, 63, 81, 87].

Coraz więcej prac dotyczy zastosowania sztucznych sieci neuronowych w analizie dynamicznej konstrukcji. W pracach [8, 9] symulowano przy pomocy sztucznych sieci neuronowych przemieszczenia budynku poddanego trzęsieniom ziemi. Natomiast w pracach [7, 23, 56] sieci neuronowe wykorzystano do nieliniowej analizy dynamicznej układów o jednym stopniu swobody, a w przypadku pracy [58] analizowano konstrukcję sprężysto – plastyczną. Następnie w pracach [10, 16, 19, 24, 26, 73, 95] analizie neuronowej poddano uszkodzenia konstrukcji w przypadku trzęsień ziemi.

Bardzo mało jest prac związanych z prognozowaniem przekazywania drgań z gruntu na fundament budynku za pomocą sztucznych sieci neuronowych. Niemniej jednak takie rozważania można znaleźć w pracach [11, 12, 38 - 41, 65].




## 2. ANALIZA WYNIKÓW BADAŃ DOŚWIADCZALNYCH

### 2.1. Uwagi wstępne

Analizie poddano przekazywanie drgań od wstrząsów górniczych w jednym z najbardziej aktywnych sejsmicznie regionów górniczych w Polsce – Legnicko Głogowskim Okręgu Miedziowym (LGOM) – z gruntu na ścianowy budynek mieszkalny o pięciu kondygnacjach, z pełnym podpiwniczeniem i poprzeczno – podłużnym układem ścian nośnych. Jest to obiekt typowy, reprezentatywny dla szerokiej klasy budynków o średniej wysokości, o zbliżonej konstrukcji i podobnych właściwościach dynamicznych.

Analizowany budynek został wykonany w następujący sposób: ściany piwnic betonowe monolityczne o grubości 30 – 40 cm, ściany nośne: wewnętrzne – prefabrykowane bloki kanałowe o grubości 24 cm, zewnętrzne – bloki prefabrykowane o grubości 24 cm wraz z blokami gazobetonowymi o grubości 12 cm oraz fakturą. Ściany podparapetowe to ściany osłonowe składające się z betonu (6 cm), ocieplenia (4 cm) i faktury (5 cm). Wewnętrzne ściany działowe zrealizowano z cegły dziurawki o grubości 6 cm, natomiast stropy wykonano w postaci żelbetowych płyt kanałowych o grubości 24 cm. Stropodach wykonano z płyty korytkowej i oparto na ażurowych ściankach z cegły dziurawki.

Fundamenty budynku są ławowe i posadowione na podłożu gruntowym: na piaskach żółtych drobno i średnio ziarnistych, poniżej glina ciemnobrązowa zailona, zwarta, poniżej żwir kwarcowy z piaskiem, różnoziarnisty, poniżej ropy zwarte z piaskiem i żwirem. Wysokość kondygnacji piwnic 2,5 m, wysokość kondygnacji naziemnych 2,8 m. Budynek posiada pełne podpiwniczenie. Wymiar w rzucie jednego segmentu budynku wynoszą 14,3 m x 11,7 m. Na rys. 2.1 schematycznie przedstawiono rzut poziomy analizowanego budynku z widocznym układem konstrukcyjnym oraz jego przekrój pionowy.

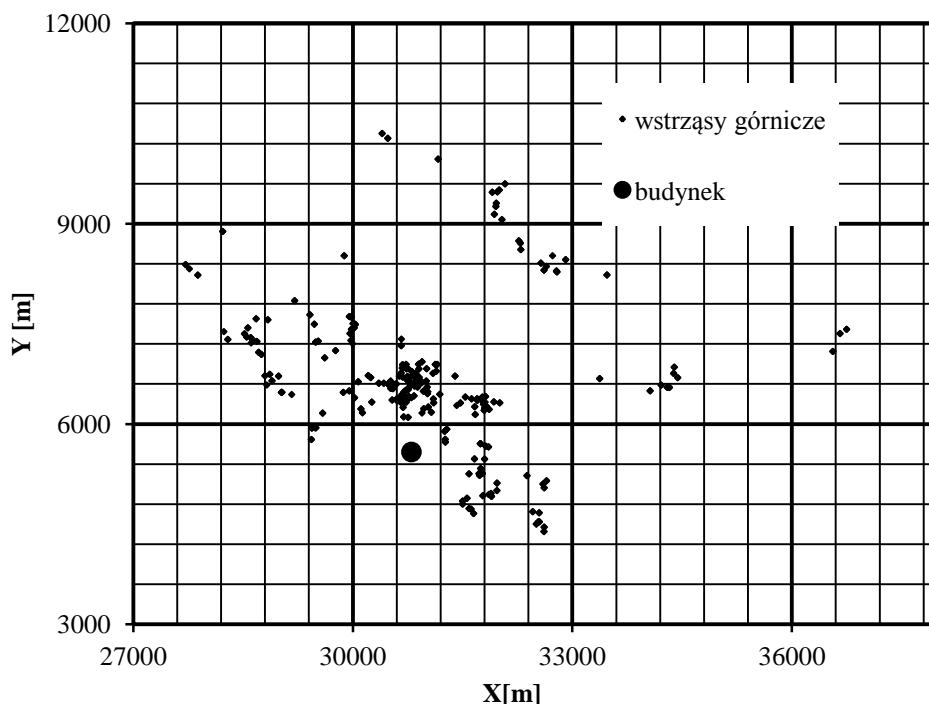


Rys. 2.1. Rzut poziomy i przekrój pionowy budynku

Źródłem analizowanych drgań były wstrząsy górnicze w Legnicko-Głogowskim Okręgu Miedziowym (LGOM). Wstrząsy te, tak samo jak w przypadku ruchu podłoża gruntowego wywołanego trzęsieniem ziemi, mają charakter losowy. W LGOM podczas silnych wstrząsów i niewielkich odległości epicentralnych przyspieszenia poziomych drgań gruntu mogą dochodzić nawet do 25 % wartości przyspieszenia ziemskiego. Intensywność silnych wstrząsów w LGOM zbliżona jest do słabych trzęsień ziemi i jest większa niż prognozowana na Słowacji, w Czechach i Niemczech od trzęsień ziemi [49, 50].

Analizie poddano wstrząsy górnicze o energiach mieszczących się w przedziale  $E_n = 7,4E3 - 2E9J$  i odległościach epicentralnych  $r_e = 270 - 5815$  m.

Na rys. 2.2 przedstawiono schematycznie mapę lokalizacji analizowanych wstrząsów górniczych z uwzględnieniem współrzędnych sejsmologicznych (X, Y) w obowiązującym w LGOM lokalnym układzie odniesienia. Widać, że zakres odległości epicentralnych i kierunków, z których do budynku docierają drgania jest bardzo szeroki.

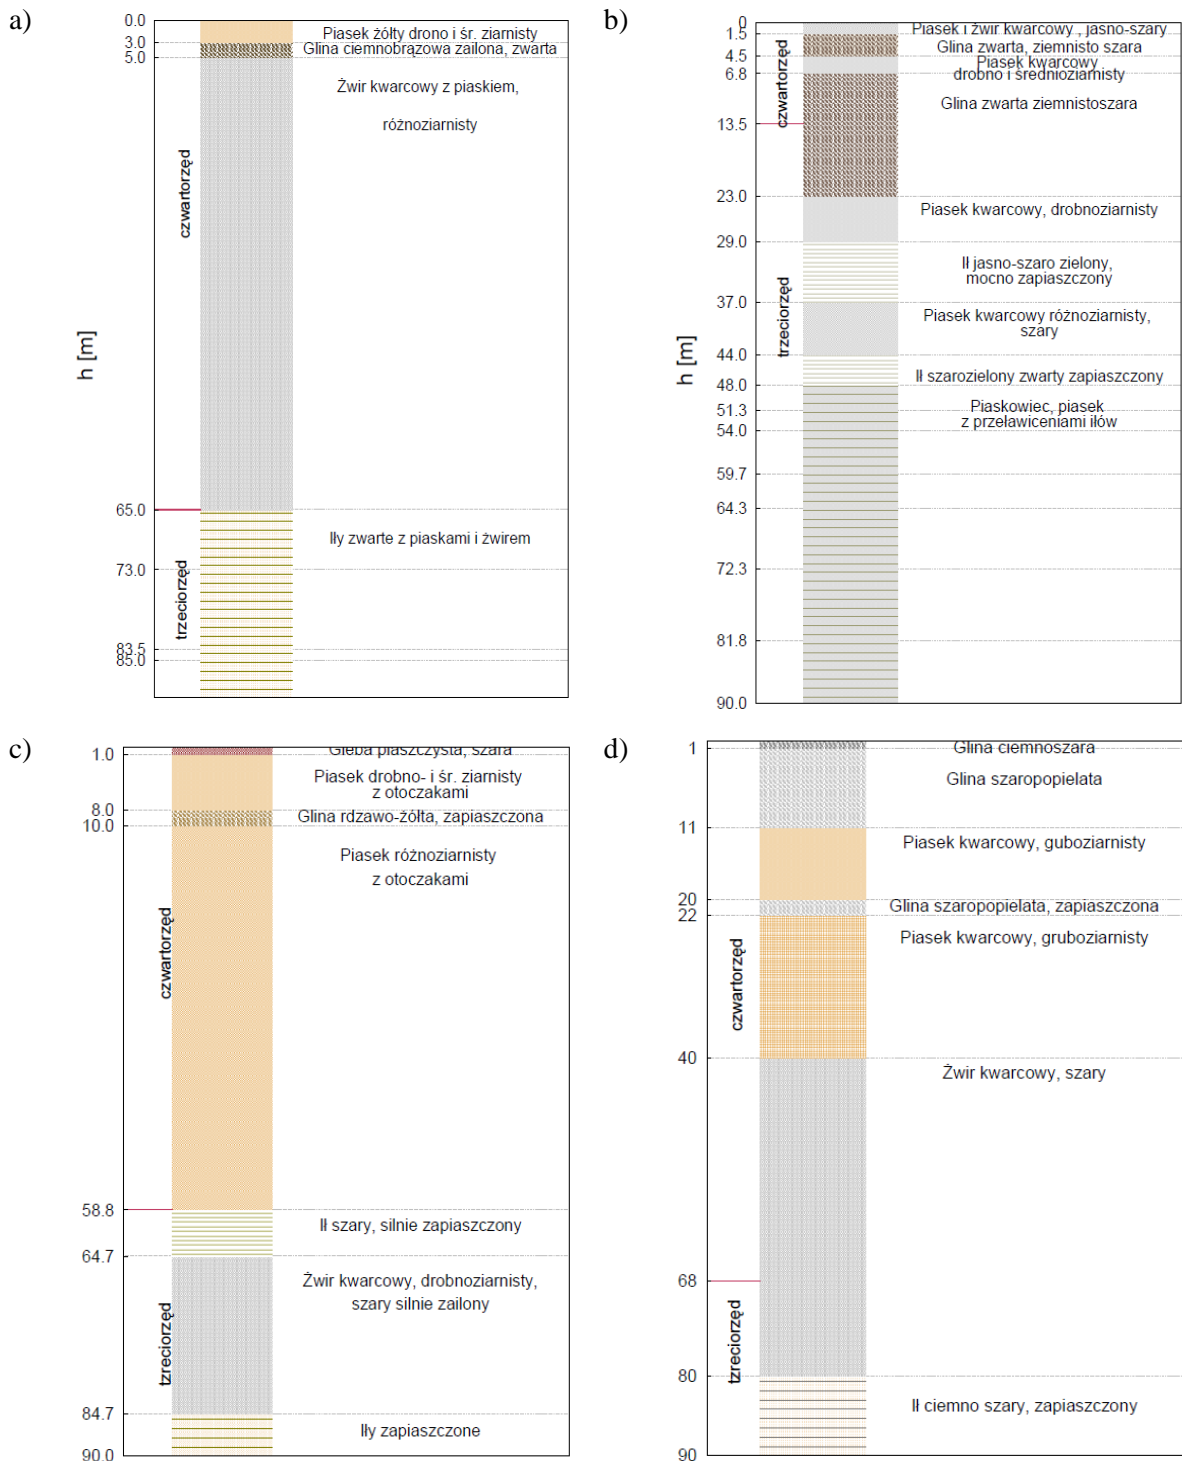


Rys. 2.2. Schematyczna mapa lokalizacji analizowanych wstrząsów górniczych i budynku

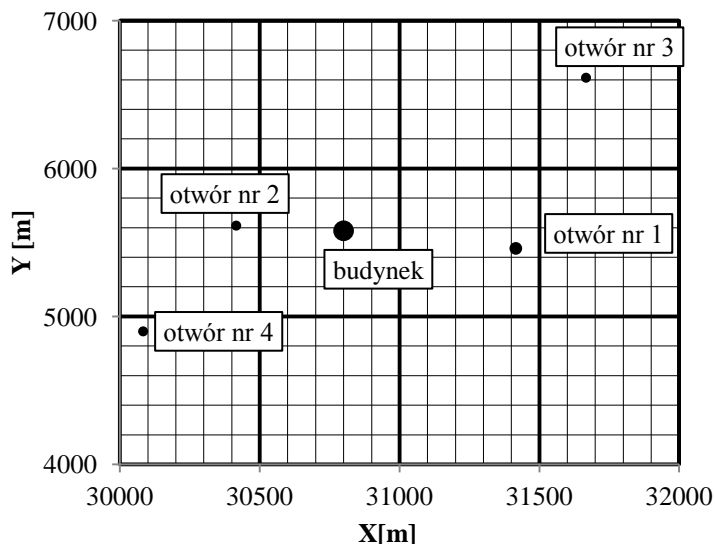
Na terenie LGOM występuje znaczne zróżnicowanie budowy geologicznej, zwłaszcza warstwy przypowierzchniowej [60].

Na rys. 2.3 a – d przedstawiono profile geologiczne do 90 metrów, otworów wiertniczych znajdujących się w okolicach analizowanego budynku. Otwór nr 1 oddalony jest o około 650 m, otwór nr 2 znajduje się około 500 m, otwór nr 3 mieści się około 1400 m, natomiast

otwór nr 4 zlokalizowano w odległości 1000 m od badanego budynku. Na rys. 2.3 e przedstawiono położenie analizowanych otworów względem badanego budynku.



e)



Rys. 2.3. Profil geologiczny otworów wiertniczych w sąsiedztwie analizowanego budynku do głębokości 90 m: a) otwór nr 1 (650m), b) otwór nr 2 (500m), c) otwór nr 3 (1400m), d) otwór nr 4 (1000m), e) położenie otworów względem analizowanego budynku [60]

W tabelach 2.1 oraz 2.2 przedstawiono liczbę rozważanych wstrząsów w zależności od współrzędnych sejsmologicznych X i Y.

Tabela 2.1

Liczba rozważanych wstrząsów w zależności od współrzędnej sejsmologicznej X

Lp.	Współrzędna sejsmologiczna X [m]	Liczba zarejestrowanych wstrząsów
1	< 30 000	46
2	30 000 – 33 000	180
3	> 33 000	12

Tabela 2.2

Liczba rozważanych wstrząsów w zależności od współrzędnej sejsmologicznej Y

Lp.	Współrzędna sejsmologiczna Y [m]	Liczba wzorców
1	< 6 000	42
2	6 000 – 8 000	169
3	> 8 000	27

Z danych zestawionych w tabeli 2.1 oraz w tabeli 2.2 wynika, że największą liczbę wstrząsów zarejestrowano (ok. 70 %) w przypadku współrzędnych sejsmologicznych zlokalizowanych w przedziałach 30 000 – 33 000 dla współrzędnej X oraz 6 000 – 8 000 dla współrzędnej Y.


Tabela 2.3 podaje liczbę zarejestrowanych wstrząsów w zależności od ich energii.

Tabela 2.3

Liczba zarejestrowanych wstrząsów w zależności od energii wstrząsu  $E_n$

Lp.	Energia wstrząsu górniczego $E_n$ [J]	Liczba zarejestrowanych wstrząsów
1	<9.9E3	1
2	9.9E3 – 9.9E4	4
3	9.9E4 – 9.9E5	66
4	9.9E5 – 9.9E6	62
5	9.9E6 – 9.9E7	83
6	9.9E7 – 9.9E8	20
7	>1,0E9	2

Z kolei na rys. 2.4 przedstawiono gęstość prawdopodobieństwa rozkładu normalnego energii rozważanych wstrząsów górnich w LGOM wraz z wartością średnią.



Rys. 2.4. Gęstość prawdopodobieństwa rozkładu normalnego energii rozważanych wstrząsów górnich w LGOM

Analizując dane zawarte w tabeli 2.3 i rys 2.4 stwierdzono, że wśród rozważanych wstrząsów górnich dominują wstrząsy o średnich i dużych energiach.

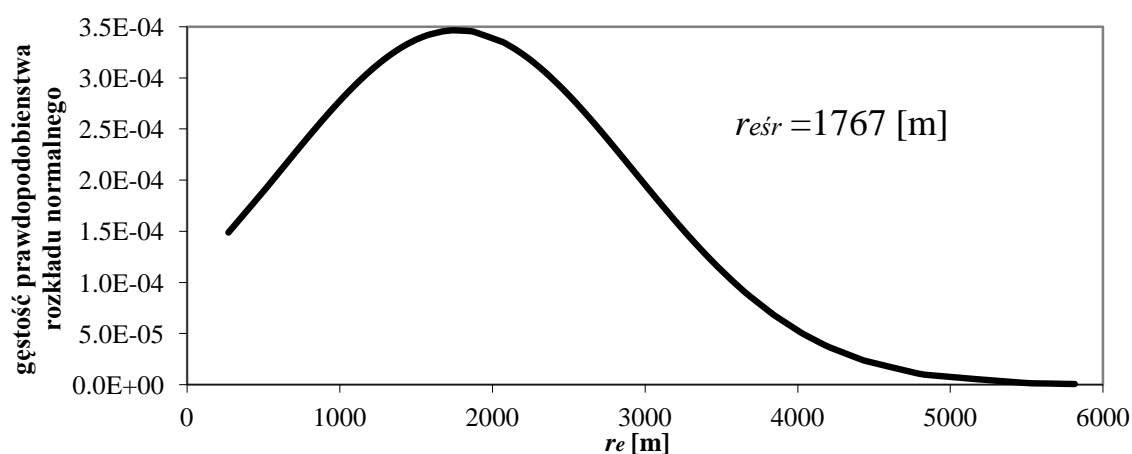
W tabeli 2.4 przedstawiono liczbę zarejestrowanych wstrząsów w zależności od odległości epicentralnych  $r_e$ .

Tabela 2.4

Liczba zarejestrowanych wstrząsów w zależności od odległości epicentralnej  $r_e$ 

Lp.	Odległość epicentralna $r_e$ [m]	Liczba zarejestrowanych wstrząsów
1	< 800	23
2	800 – 1 500	119
3	> 1 500	96

Rys. 2.5 przedstawia gęstość prawdopodobieństwa rozkładu normalnego odległości epicentralnych rozważanych wstrząsów górniczych w LGOM wraz z wartością średnią.



Rys. 2.5. Gęstość prawdopodobieństwa rozkładu normalnego odległości epicentralnych rozważanych wstrząsów górniczych w LGOM

Stwierdzono, że z analizowanej grupy pomiarów, epicentrum około połowy wstrząsów górniczych znajdowało się w odległości 800 – 1500 metrów od analizowanego budynku. Natomiast ok. 35 % wszystkich zarejestrowanych wstrząsów było w odległości  $r_e > 1500$  m. Stosunkowo mało wstrząsów pochodzi ze źródeł w bliskiej odległości epicentralnej.

## 2.2. Analiza różnic w jednocześnie zarejestrowanych drganiach gruntu obok budynku i fundamentu budynku

Za pomocą aparatury „czuwającej” mierzono poziome przyspieszenia drgań gruntu i budynku. Czujniki pomiarowe na gruncie umieszczone są w odległości kilku metrów od budynku, a czujniki w budynku ustawiono na fundamentach. Narzędzia pomiarowe na gruncie zostały ustawione w odległości ok. 6 metrów od analizowanego budynku w celu uniknięcia wpływu drgań budynku na drgania gruntu. Mierzono przebiegi przyspieszeń drgań równocześnie na gruncie i na fundamencie budynku od wielu wstrząsów górniczych [42, 43]. Uwagę skupiono na dwóch składowych drgań poziomych:  $x$  i  $y$ , odpowiednio równoległych do osi poprzecznej i podłużnej budynku.


Na podstawie pomierzonych składowych przebiegów przyspieszeń drgań, w przypadku każdego wstrząsu górniczego, przez całkowanie wyznaczono przebiegi prędkości drgań. Na podstawie pomierzonych składowych przebiegów przyspieszeń drgań w kierunkach  $x$  i  $y$ , w przypadku każdego wstrząsu górniczego wyliczono również przebiegi wartości wypadkowego przyspieszenia drgań poziomych, odpowiednio na gruncie i na fundamencie budynku. Analogicznie otrzymano przebiegi wartości wypadkowej prędkości drgań poziomych na gruncie i na fundamencie budynku. Wartość drgań wypadkowych gruntu jest jednym z parametrów używanych w Górniczej Skali Intensywności (GSI – 2004 i jej uaktualnionej wersji GSI – 2004/11) do oceny oddziaływań drgań na obiekty powierzchniowe [99].

Łącznie rozważono 928 składowych przebiegów przyspieszeń drgań (464 pary grunt – fundament) i taką samą liczbę składowych przebiegów prędkości drgań. W przypadku wypadkowych przyspieszeń oraz wypadkowych prędkości drgań przeanalizowano po 226 par grunt – fundament, które odpowiadają tym samym wstrząsom górniczym (904 przebiegi przyspieszeń oraz 904 przebiegi prędkości drgań gruntu i fundamentu budynku w kierunkach  $x$  i  $y$ ).

W niniejszym rozdziale skupiono uwagę na porównaniu przebiegów drgań składowych i wypadkowych przyspieszeń oraz prędkości drgań pomierzonych równocześnie na gruncie oraz na fundamencie badanego obiektu.


Maksymalna wartość przyspieszenia drgań składowych jaką zmierzono na gruncie wynosi: dla kierunku  $x$  (równoległa do osi poprzecznej)  $a_{xgmax}=1,35 \text{ m/s}^2$  natomiast dla kierunku  $y$  (równoległa do osi podłużnej)  $a_{ygmax}= 1,02 \text{ m/s}^2$ . W przypadku przyspieszeń drgań pomierzonych na fundamencie analizowanego budynku, zarejestrowano maksymalne wartości równe: dla kierunku  $x$   $a_{xfmax}= 0,66 \text{ m/s}^2$  natomiast dla kierunku  $y$  (równoległa do osi podłużnej)  $a_{yfmax}= 1,02 \text{ m/s}^2$ .

Na rys. 2.6 oraz rys. 2.7 przedstawiono przykładowe przebiegi przyspieszeń drgań pomierzonych równocześnie na gruncie oraz na fundamencie rozważanego budynku od wstrząsu górniczego  $En = 4,1E7 \text{ J}$  i  $r_e = 1567 \text{ m}$  (rys. 2.6) oraz od wstrząsu górniczego  $En = 3,9E6 \text{ J}$  i  $r_e = 580 \text{ m}$  (rys. 2.7).



Rys. 2.6. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $En = 4,1E7 \text{ J}$  i  $r_e = 1567 \text{ m}$






Rys. 2.7. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w kierunku y w przypadku wstrząsu górniczego  $En = 3,9E6 \text{ J}$  i  $r_e = 580 \text{ m}$

Stwierdzono, że różnice w drganiach gruntu i fundamencie odbywających się w tym samym czasie mogą być znaczące w zakresie składowych przyspieszeń drgań.


Maksymalna wartość prędkości drgań gruntu wynosi: dla kierunku  $x$  (równoległa do osi poprzecznej)  $v_{xgmax} = 57 \text{ mm/s}$  natomiast dla kierunku  $y$  (równoległa do osi podłużnej)  $v_{ygmax} = 58 \text{ mm/s}$ . W przypadku prędkości drgań w poziomie fundamencie analizowanego budynku, maksymalne wartości wynoszą odpowiednio: dla kierunku  $x$   $v_{xfmax} = 52 \text{ mm/s}$  natomiast dla kierunku  $y$  (równoległa do osi podłużnej)  $v_{yfmax} = 76 \text{ mm/s}$ .

Na rys. 2.8 oraz rys. 2.9 przedstawiono przykładowe wykresy przebiegów prędkości drgań występujących równocześnie na gruncie oraz na fundamencie rozważanego budynku od wstrząsu górniczego  $En = 9,5E6 \text{ J}$  i  $r_e = 698 \text{ m}$  w kierunku  $x$  (rys. 2.8) oraz od wstrząsu górniczego  $En = 1,9E7 \text{ J}$  i  $r_e = 3562 \text{ m}$  (rys. 2.9).



Rys. 2.8. Przebieg prędkości drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $En = 9,5E6 \text{ J}$  i  $r_e = 698 \text{ m}$

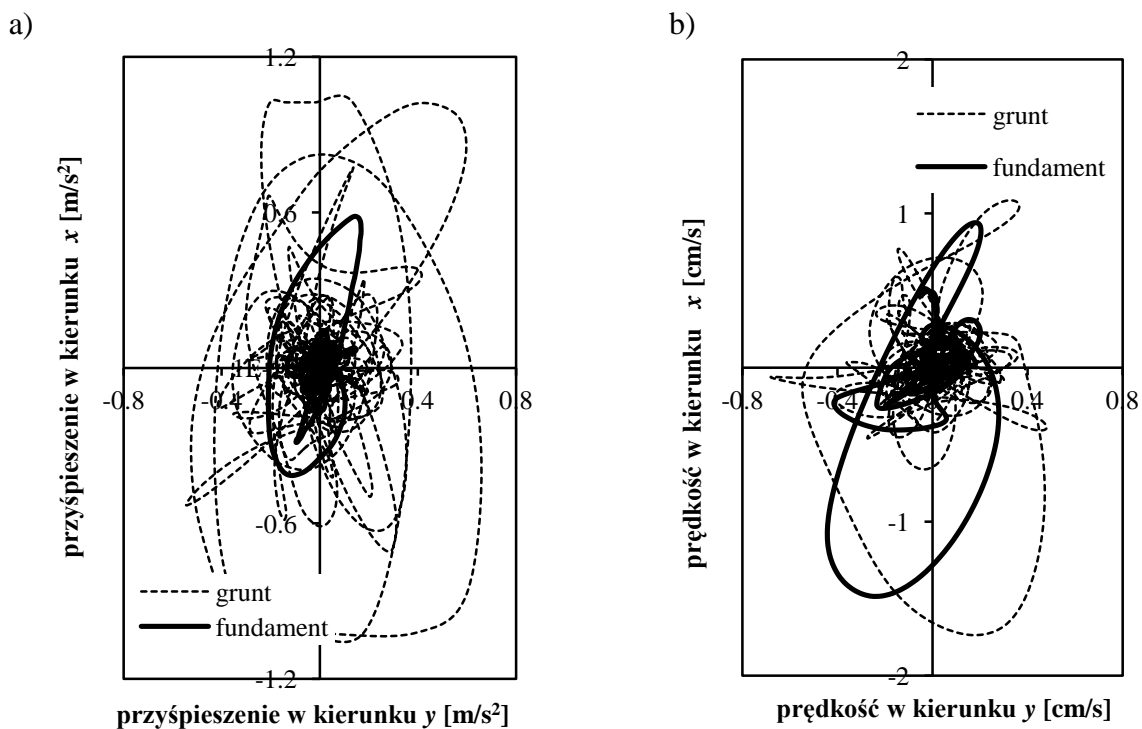




Rys. 2.9. Przebieg prędkości drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $En = 1,9E7$  J i  $r_e = 3562$  m

Analogicznie jak w przypadku składowych przyspieszeń drgań zauważono, iż różnice w drganiach gruntu i fundamentu odbywających się w tym samym czasie mogą być znaczące w przypadku składowych prędkości.


Przykładowe porównanie trajektorii końca wypadkowego wektora przyspieszeń oraz prędkości drgań jednocześnie występujących na gruncie i na fundamencie rozważanego budynku pokazano na rys. 2.10 [39].




Rys. 2.10. Trajektorie końca wypadkowego wektora przyspieszeń drgań (a) oraz prędkości drgań (b) jednocześnie występujących na gruncie i na fundamencie rozważanego budynku w przypadku wstrząsu górniczego:  $En=1.2E7$ J,  $r_e=698$ m [39]

Na rys. 2.11 oraz rys. 2.12 przedstawiono przykładowe wykresy przebiegów wypadkowych przyspieszeń oraz wypadkowych prędkości pomierzonych równocześnie na gruncie oraz na

fundamencie rozważanego budynku od wstrząsu górniczego  $En = 2,6E7$  J i  $r_e = 1540$  m (rys. 2.11) oraz od wstrząsu górniczego  $En = 8,3E6$  J i  $r_e = 1569$  m (rys. 2.12).




Rys. 2.11. Przebieg wypadkowych przyspieszeń drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $En = 2,6E7$  J i  $r_e = 1540$  m



Rys. 2.12. Przebieg wypadkowych prędkości drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $En = 8,3E6$  J i  $r_e = 1569$  m

Stwierdzono, że różnice w drganiach gruntu i fundamentu odbywających się w tym samym czasie mogą być znaczące tak w zakresie przyspieszeń drgań wypadkowych, jak i prędkości drgań wypadkowych.


Na rys. 2.13 przedstawiono przebieg składowej przyspieszeń drgań w kierunku  $x$  (a), składowej przyspieszeń drgań w kierunku  $y$  (b) oraz wypadkowej przyspieszeń drgań (c) w przypadku tego samego wstrząsu górniczego o energii  $En = 8,3E7$  J oraz odległości epicentralnej  $r_e = 3180$  m.



Rys. 2.13. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $E_n = 8,3E7$  J i  $r_e = 3180$  m: a) składowa w kierunku  $x$ , b) składowa w kierunku  $y$ , c) wypadkowa

Stwierdzono, że w przypadku tego samego wstrząsu, zarówno składowe przyspieszenia w kierunku  $x$ , w kierunku  $y$ , jak i wypadkowe przyspieszenia pomierzone równocześnie na gruncie oraz fundamencie różnią się od siebie. Zauważono, że w przypadku rozważanego wstrząsu przyspieszenia na fundamencie budynku są mniejsze niż przyspieszenia drgań na gruncie zarówno w przypadku kierunku poprzecznego  $x$ , kierunku podłużnego  $y$ , jak i wypadkowych przyspieszeń.


Na rys. 2.14 przedstawiono przebieg prędkości drgań w czasie dla składowych prędkości drgań w kierunku  $x$  (a), składowych prędkości drgań w kierunku  $y$  (b) oraz wypadkowych prędkości (c) dla wstrząsu górniczego o energii  $E_n = 1,6E8$  J oraz odległości epicentralnej  $r_e = 2090$  m.




Rys. 2.14. Przebieg prędkości drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $En = 1,6E8$  J i  $r_e = 2090$  m: a) składowa w kierunku  $x$ , b) składowa w kierunku  $y$ , c) wypadkowa

Zauważono, iż w przypadku składowych prędkości drgań zarówno kierunku  $x$  jak i w kierunku  $y$  oraz w przypadku prędkości drgań wypadkowych pomierzonych równocześnie na gruncie oraz na fundamencie, występują różnice. Niemniej jednak różnice te są mniejsze niż w przypadku składowych oraz wypadkowych przyspieszeń drgań.

Na podstawie przebiegów przyspieszeń oraz prędkości drgań, przy użyciu szybkiej transformacji Fouriera (FFT) wyznaczono odpowiednie widma amplitudowe. Na rys. 2.15 oraz rys. 2.16 przedstawiono przykładowe wykresy w przypadku przyspieszeń drgań gruntu od wstrząsu górniczego  $En = 6,4E7$  J i  $r_e = 629$  m w kierunku  $x$  oraz od wstrząsu górniczego  $En = 4,7E6$  J i  $r_e = 508$  m w kierunku  $y$ .




Rys. 2.15. Widmo amplitudowe przyspieszeń drgań gruntu w przypadku wstrząsu górniczego  $E_n = 6,4 E7 J$  i  $r_e = 629$  m w kierunku  $x$




Rys. 2.16. Widmo amplitudowe przyspieszeń drgań gruntu w przypadku wstrząsu górniczego  $E_n = 4,7E6 J$  i  $r_e = 508$  m w kierunku  $y$

Na rys. 2.17 i rys. 2.18 przedstawiono przykładowe wykresy zależności amplitud od częstotliwości w przypadku innego wstrząsu górniczego  $E_n = 7,1E7 J$  i  $r_e = 1724$  m w kierunku  $x$  oraz w kierunku  $y$ .

Analizując wyniki FFT w przypadku wszystkich rozważanych wstrząsów górniczych stwierdzono, że zakres dominujących częstotliwości drgań w poszczególnych przebiegach przyspieszeń drgań jest bardzo szeroki.




Rys. 2.17. Dominujące częstotliwości przyspieszeń drgań w przypadku wstrząsu górnicego  
 $En = 7,1E7$  J i  $r_e = 1724$  m w kierunku  $x$



Rys. 2.18. Dominujące częstotliwości przyspieszeń drgań w przypadku wstrząsu górnicego  
 $En = 7,1E7$  J i  $r_e = 1724$  m w kierunku  $y$

Na rysunku 2.19 a, b przykładowo porównano dwie pary przebiegów przyspieszeń drgań jednocześnie zarejestrowanych na gruncie i na fundamencie w kierunku  $y$  rozważanego budynku. Źródłem drgań w obu tych przypadkach były wstrząsy górnice o takich samych energiach i niemal takich samych odległościach epicentralnych. Mimo tego, sposób przekazywania drgań w tych przypadkach jest różny, co widać na rys. 2.19 a, b. Na uwagę zasługuje fakt, że mimo prawie takich samych odległości epicentralnych, położenie epicentrum wstrząsu w stosunku do budynku w każdym z tych wstrząsów jest inne, a więc różny jest kierunek dotarcia fali (por. rys. 2.19 c).



Rys. 2.19. Przebiegi przyśpieszeń drgań w kierunku y w przypadku wstrząsu górniczego:  
 a)  $E_n = 1.2E6 \text{ J}$ ,  $r_e = 1172 \text{ m}$ , b)  $E_n = 1.2E6 \text{ J}$ ,  $r_e = 1178 \text{ m}$ ; c) położenie epicentrum wstrząsów (a) i (b) w stosunku do położenia budynku

Rozważając wpływ wzajemnego położenia epicentrum wstrząsu górniczego i budynku na przekazywanie drgań z podłoża na obiekt, pośrednio analizuje się wpływ rodzaju podłoża na propagację fali. Widać, że w zależności od lokalnych warunków geologicznych, drgania powierzchniowe wzbudzone wstrząsami górniczymi w LGOM mogą propagować się w różnych kierunkach z odmiennymi intensywnościami, co wskazuje na kierunkowość emisji. Różny może być więc charakter drgań gruntu obok budynku i dalej różny sposób przekazywania tych drgań na budynek.

## 2.3. Ocena przekazywania drgań z podłoża na budynek

### 2.3.1. Wstęp

Oceny przekazywania drgań z gruntu na fundament budynku dokonano poprzez porównanie maksymalnych wartości jednocześnie występujących drgań fundamentu i gruntu obok budynku. Maksymalne amplitudy na gruncie i na fundamencie nie zawsze pojawiają się w tym samym czasie z uwagi na to, że na styku grunt – fundament na ogół następuje modyfikacja przebiegu drgań. Ocena przekazywania drgań poprzez maksymalne amplitudy drgań jest pewnym uproszczeniem, gdyż nie uwzględnia istotnego parametru drgań jakim jest częstotliwość drgań. Taki sposób oceny przekazywania drgań wykorzystano w przypadku drgań powierzchniowych m. in. w [75, 82].

Analizowano przekazywanie przyspieszeń i prędkości drgań składowych oraz przyspieszeń i prędkości drgań wypadkowych. W przypadku przyspieszeń i prędkości drgań składowych (w kierunkach równoległych do osi poprzecznej  $x$  i osi podłużnej  $y$  budynku) przekazywanie drgań z gruntu na budynek rozważano osobno w kierunku  $x$ , osobno w kierunku  $y$  oraz łącznie w obu kierunkach  $x$  i  $y$ .

I tak w przypadku analizy przekazywania przyspieszeń drgań składowych z gruntu na fundament budynku, wyznaczono ułamki:

$$r_{ax} = a_{xfmax}/a_{xgmax}, \quad (2.1)$$

gdy rozważano tylko kierunek poprzeczny  $x$ ,

$$r_{ay} = a_{yfmax}/a_{ygmax}, \quad (2.2)$$

gdy analizowano osobno kierunek podłużny  $y$ , gdzie:

- $a_{xfmax}, a_{yfmax}$  – odpowiednio: maksymalne przyspieszenie drgań fundamentu w kierunku  $x$  oraz w kierunku  $y$ ,  
 $a_{xgmax}, a_{ygmax}$  – odpowiednio: maksymalne przyspieszenie drgań gruntu w kierunku  $x$  oraz w kierunku  $y$ .

Przez  $r_{axy}$  oznaczono wartości tych ułamków podczas łącznej analizy w zbiorze par grunt-budynek w obu kierunkach  $x$  i  $y$ .

Analogiczne oznaczenia zaproponowano w przypadku analizy przekazywania prędkości drgań składowych z gruntu na fundament budynku:

$$r_{vx} = v_{xfmax}/v_{xgmax}, \quad (2.3)$$



gdy rozważano tylko kierunek poprzeczny  $x$ ,

$$r_{vy} = v_{yfmax}/v_{ygmax}, \quad (2.4)$$

gdy analizowano osobno kierunek podłużny  $y$ , gdzie:

- $v_{xfmax}, v_{yfmax}$  – odpowiednio: maksymalna prędkość drgań fundamentu w kierunku  $x$  oraz w kierunku  $y$ ,
- $v_{xgmax}, v_{ygmax}$  – odpowiednio: maksymalna prędkość drgań gruntu w kierunku  $x$  oraz w kierunku  $y$ .

Przez  $r_{vxy}$  oznaczono wartości tych ułamków podczas łącznej analizy w zbiorze par grunt-budynki w obu kierunkach  $x$  i  $y$ .

Na podstawie pomierzonych składowych przebiegów przyspieszeń drgań w kierunkach  $x$  i  $y$ , w przypadku każdego wstrząsu wyliczono maksymalne wartości wypadkowego przyspieszenia drgań poziomych  $PGA$  i  $PFA$ , odpowiednio na gruncie i na fundamencie budynku:

$$PGA = \max_t \left( \sqrt{a_{xg}^2(t) + a_{yg}^2(t)} \right), \quad (2.5)$$

$$PFA = \max_t \left( \sqrt{a_{xf}^2(t) + a_{yf}^2(t)} \right), \quad (2.6)$$

gdzie:

- $a_{xg}(t), a_{yg}(t)$  – odpowiednio przyspieszenia drgań na gruncie w kierunkach  $x$  i  $y$  w kolejnych chwilach czasu,
- $a_{xf}(t), a_{yf}(t)$  – odpowiednio przyspieszenia drgań na fundamencie w kierunkach  $x$  i  $y$  w kolejnych chwilach czasu.

Analogicznie otrzymano maksymalne wartości wypadkowej prędkości drgań poziomych  $PGV$  i  $PFV$ , odpowiednio na gruncie i na fundamencie budynku:

$$PGV = \max_t \left( \sqrt{v_{xg}^2(t) + v_{yg}^2(t)} \right), \quad (2.7)$$

$$PFV = \max_t \left( \sqrt{v_{xf}^2(t) + v_{yf}^2(t)} \right), \quad (2.8)$$

gdzie:

$v_{xg}(t), v_{yg}(t)$  – odpowiednio prędkości drgań na gruncie w kierunkach  $x$  i  $y$  w kolejnych chwilach czasu,

$v_{xf}(t), v_{yf}(t)$  – odpowiednio prędkości drgań na fundamencie w kierunkach  $x$  i  $y$  w kolejnych chwilach czasu,

W celu porównania maksymalnych wartości wypadkowych przyspieszeń drgań jednocześnie zarejestrowanych na fundamencie budynku ( $PFA$ ) i gruntu obok budynku ( $PGA$ ) wyliczano stosunek:

$$r_{WA} = PFA/PGA, \quad (2.9)$$

a w przypadku wypadkowych prędkości drgań:

$$r_{WV} = PFV/PGV, \quad (2.10)$$

$PFA, PGA$  – odpowiednio: maksymalna wartość wypadkowej przyspieszeń drgań fundamentu i gruntu obok budynku,


$PFV, PGV$  – odpowiednio: maksymalna wartość wypadkowej prędkości drgań fundamentu i gruntu obok budynku.

Wykorzystując wyniki badań doświadczalnych w skali naturalnej analizowano przekazywanie drgań z gruntu na fundament budynku w zależności od podstawowych parametrów wstrząsów górniczych takich jak energia wstrząsów górniczych  $En$ , odległość epicentralna  $r_e$ , współrzędne sejsmologiczne  $X$  i  $Y$ , a także parametrów drgań takich jak maksymalna wartość drgań gruntu (przyspieszenie albo prędkość drgań składowych oraz wypadkowych), dominująca częstotliwość drgań gruntu  $f_{lg}$  oraz kierunek drgań odpowiednio równoległy do osi poprzecznej  $x$  oraz osi podłużnej  $y$  analizowanego budynku w przypadku uwzględnienia drgań składowych.

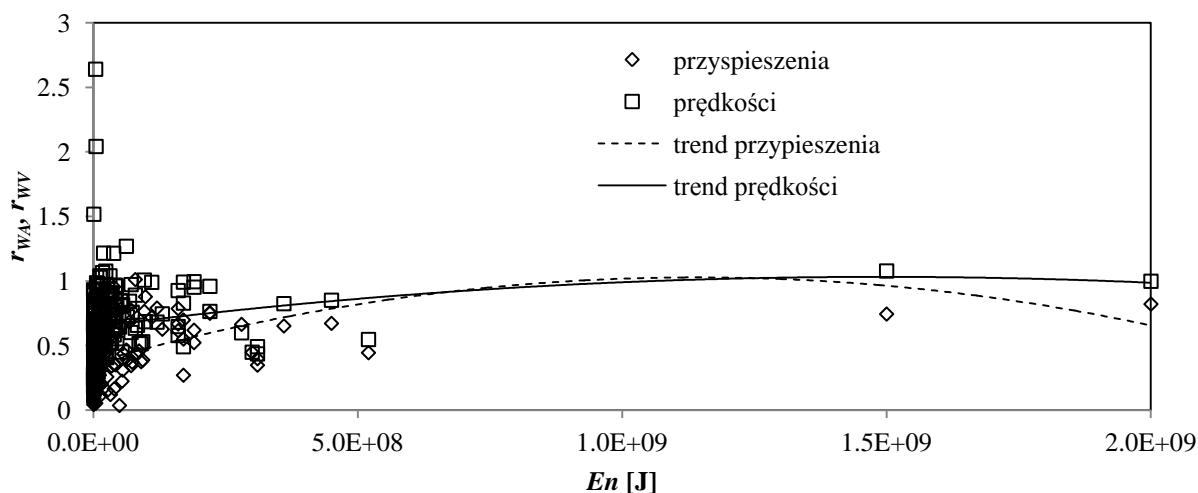
### 2.3.2. Wpływ energii wstrząsów górniczych $En$ na przekazywanie drgań z gruntu na fundament budynku

Przykładowo na rys. 2.20 porównano wartości ułamków  $r_{axy}$  i  $r_{vxy}$  wyliczonych w przypadku składowych przyspieszeń oraz prędkości drgań w funkcji energii wstrząsów  $En$ .

Analogicznego porównania dokonano na rys. 2.21 w odniesieniu do przyspieszeń oraz prędkości drgań wypadkowych.



Rys. 2.20. Porównanie ułamków  $r_{axy}$ ,  $r_{vxy}$  w zależności od energii wstrząsów górniczych  $En$



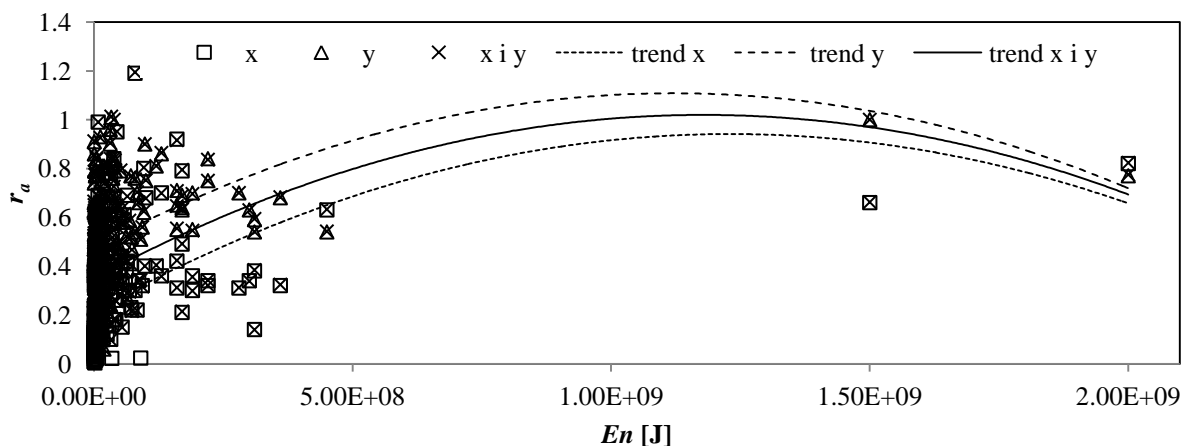
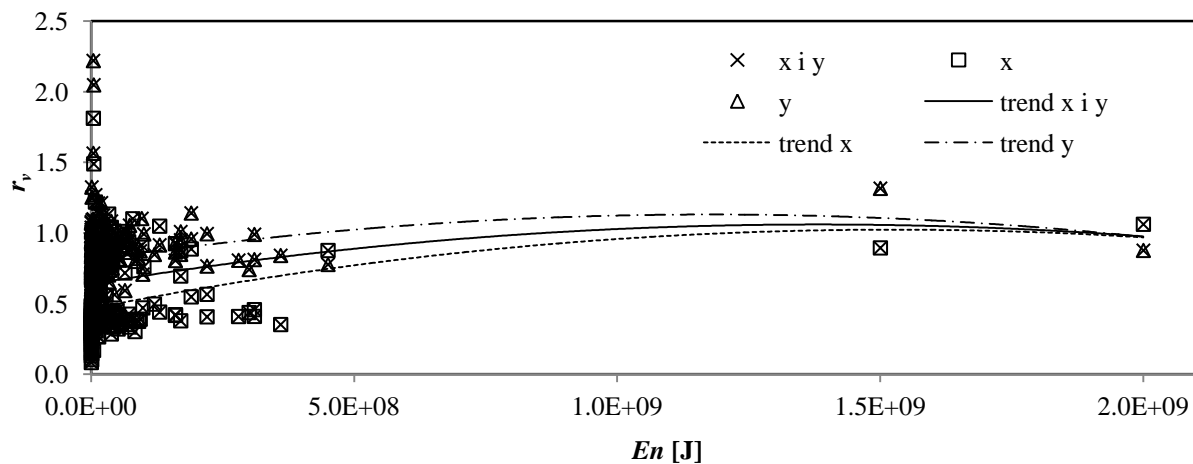
Rys. 2.21. Porównanie ułamków  $r_{WA}$ ,  $r_{WV}$  w zależności od energii wstrząsów górniczych  $En$

Zależność wartości ułamka  $r_a$  od energii  $En$  wszystkich analizowanych wstrząsów górniczych wraz z liniami trendu pokazano na rys. 2.22. Natomiast na rys. 2.23 przedstawiono ułamek  $r_v$  w zależności od  $En$ . Dodatkowo odpowiednio na rys. 2.22 oraz rys. 2.23 przedstawiono te zależności osobno w kierunku  $x$  i kierunku  $y$ .

W tabeli 2.5 porównano średnie wartości tych ułamków wyliczone w przedziale energii wstrząsów do  $5E7J$  oraz powyżej tej wartości.

Zależność średnich wartości ułamków  $r$  od energii wstrząsów górniczych  $En$ 

Energia wstrząsów górniczych	Wartość średnia $r$							
	przyspieszenia				prędkości			
	$r_{axy}$	$r_{ax}$	$r_{ay}$	$r_{WA}$	$r_{vxv}$	$r_{vx}$	$r_{vy}$	$r_{wv}$
$\leq 5E7$	0,36	0,22	0,49	0,37	0,64	0,46	0,80	0,64
$> 5E7$	0,54	0,44	0,65	0,59	0,76	0,62	0,91	0,74

Rys. 2.22. Zależność ułamka  $r_a$  od energii wstrząsów górniczych  $En$ Rys. 2.22. Zależność ułamka  $r_v$  od energii wstrząsów górniczych  $En$ 

Stwierdzono (rys. 2.22, tabela 2.5), że redukcja składowych przyspieszeń drgań przy przekazywaniu ich z gruntu na fundament budynku w poszczególnych kierunkach jest wyraźnie mniejsza w przypadku większych energii wstrząsów górniczych. Niemniej jednak redukcja drgań w przypadku tych samych energii jest zdecydowanie większa w kierunku poprzecznym  $x$ , niż w kierunku podłużnym  $y$  analizowanego budynku. Analogiczną redukcję jak w przypadku składowych przyspieszeń drgań obserwuje się w przypadku składowych

prędkości drgań (por. rys. 2.23, tabela 2.5). Średnie wartości ułamka  $r_a$ ,  $r_v$  (por. tabela 2.5) również potwierdzają to spostrzeżenie.

W przypadku analizy redukcji wypadkowych przyspieszeń drgań przy przekazywaniu z gruntu na fundament budynku w zależności od energii wstrząsów górniczych  $En$  zauważono, iż określenie dokładnej zależności redukcji drgań jest bardzo trudne. Jest to spowodowane dużym „rozrzutem” ułamka  $r$ . Zauważono, że zarówno w przypadku wypadkowych przyspieszeń, jak i wypadkowych prędkości drgań, redukcja drgań przy przekazywaniu ich z podłoża na budynek jest mniejsza w przypadku większych energii. Zdecydowanie większą różnicę w redukcji maksymalnych wartości wypadkowych prędkości drgań i maksymalnych wartości wypadkowych przyspieszeń drgań obserwuje się w przypadku małych energii wstrząsów.


Porównując dane dotyczące składowych przyspieszeń drgań oraz składowych prędkości drgań stwierdzono, iż w poszczególnych przedziałach  $En$  lepiej przekazują się prędkości drgań, co potwierdzają odpowiednie wartości średnie ułamków. Wartości ułamków  $r_{vxy}$ ,  $r_{vx}$ ,  $r_{vy}$  są około 1,5 razy większe niż odpowiadające im ułamki  $r_{axy}$ ,  $r_{ax}$ ,  $r_{ay}$ , w przypadku drgań składowych od wstrząsów o większych energiach ( $En > 5E7$ ). Nieco mniejszą różnicę obserwuje się w przypadku porównania ułamków  $r_{WA}$ ,  $r_{WV}$ . Niemniej jednak drgania lepiej przekazują się z gruntu na fundament budynku w przypadku wypadkowych prędkości drgań, niż wypadkowych przyspieszeń drgań.

W przypadku mniejszych energii wstrząsów górniczych ( $En \leq 5E7$ ) zauważono analogiczną tendencję, z tym, że różnice w wartościach ułamków są jeszcze większe. W przypadku składowych prędkości drgań wartości ułamków  $r$  są ok. 2 razy większe niż w przypadku składowych przyspieszeń drgań (por. tabela 2.5).

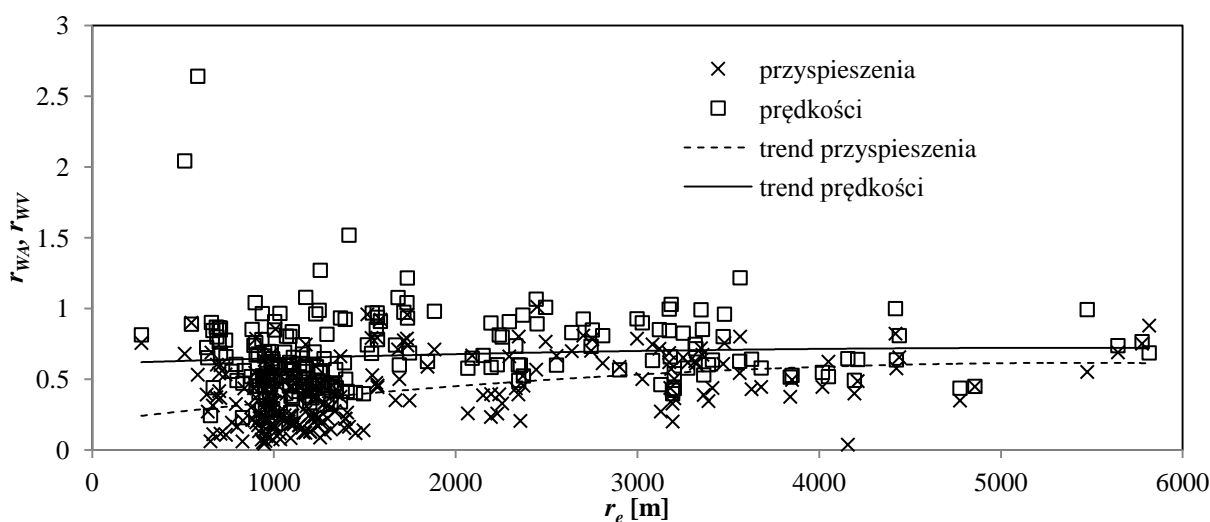
Również linie trendu (por. rys. 2.20 oraz rys. 2.21) wskazują, że drgania lepiej są przekazywane z gruntu na fundament budynku w przypadku składowych oraz wypadkowych prędkości drgań, niż w przypadku przyspieszeń drgań.

### **2.3.3. Wpływ odległości epicentralnej $r_e$ na przekazywanie drgań z gruntu na fundament budynku**

Na rys. 2.24 porównano wartości ułamków  $r$  wyliczonych w przypadku składowych przyspieszeń oraz prędkości drgań pomierzonych równocześnie w kierunku  $x$  i  $y$ , w funkcji odległości epicentralnej  $r_e$ . Analogicznego porównania dokonano na rys. 2.25 w odniesieniu do drgań wypadkowych.



Rys. 2.24. Porównanie ułamków  $r_{axy}$ ,  $r_{vxy}$  w zależności od odległości epicentralnej  $r_e$



Rys. 2.25. Porównanie ułamków  $r_{WA}$ ,  $r_{WV}$  w zależności od odległości epicentralnej  $r_e$

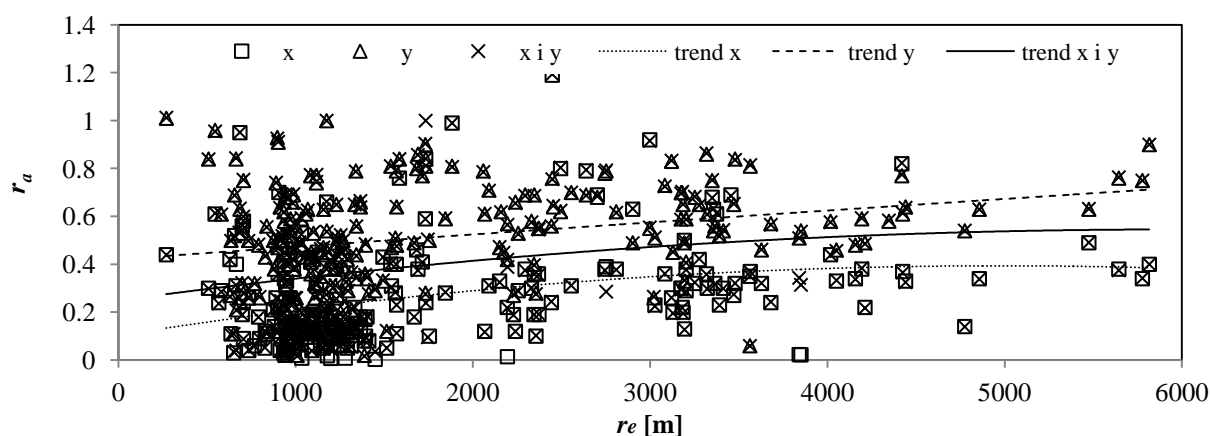
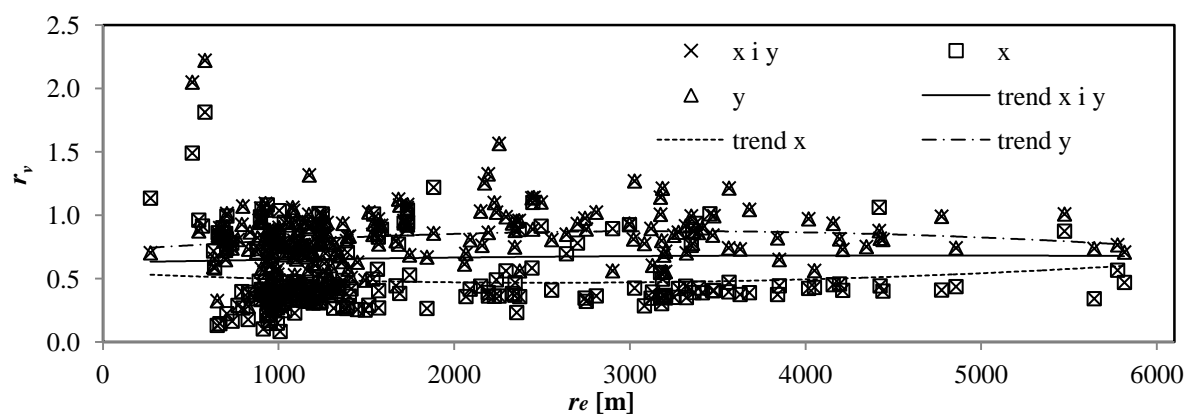
Zależność wartości ułamka  $r_a$  od odległości epicentralnej  $r_e$  wszystkich analizowanych wstrząsów górniczych wraz z liniami trendu pokazano na rys. 2.26. Natomiast na rys. 2.27 przedstawiono ułamek  $r_v$  w zależności od  $r_e$ . Dodatkowo odpowiednio na rys. 2.26 oraz rys. 2.27 przedstawiono te zależności osobno w kierunku  $x$ , jak i kierunku  $y$ .

Natomiast w tabeli 2.6 porównano średnie wartości tych ułamków wyliczone w przedziałach odległości epicentralnych  $r_e$ .

Tabela 2.6

Zależność średnich wartości ułamków  $r$  od odległości epicentralnych  $r_e$ 

Odległości epicentralne $r_e$	Wartość średnia $r$							
	przyspieszenia				prędkości			
	$r_{axy}$	$r_{ax}$	$r_{ay}$	$r_{WA}$	$r_{vxy}$	$r_{vx}$	$r_{vy}$	$r_{wv}$
$r_e \leq 800$	0,41	0,30	0,52	0,41	0,81	0,73	0,89	0,81
$800 < r_e < 1500$	0,30	0,17	0,44	0,30	0,59	0,42	0,76	0,56
$r_e > 1500$	0,49	0,37	0,61	0,56	0,71	0,54	0,88	0,75

Rys. 2.26. Zależność ułamka  $r_a$  od odległości epicentralnej  $r_e$ Rys. 2.27. Zależność ułamka  $r_v$  od odległości epicentralnej  $r_e$ 

Analizując zależność ułamka  $r_a$  od odległości epicentralnych  $r_e$  w przypadku składowych przyspieszeń drgań stwierdzono, że największa redukcja ma miejsce w przypadku kierunku  $x$ , natomiast drgania najlepiej przekazują się w przypadku kierunku  $y$  (tabela 2.6, rys. 2.26). W obu kierunkach składowe przyspieszenia drgań najlepiej przekazują się w przypadku odległości epicentralnych  $r_e > 1500$  m (tabela 2.6).

Można zauważyć, że średnio biorąc (tabela 2.6) składowe prędkości drgań gruntu przekazują się najlepiej na fundament budynku w przypadku najmniejszych odległości

epicentralnych wstrząsów ( $r_e \leq 800$ ) i w nieco mniejszym stopniu przy odległościach dużych ( $r_e > 1500$ ). Stwierdzono, że redukcja prędkości w przypadku kierunku  $y$  jest zdecydowanie mniejsza niż w kierunku  $x$ . Z rys. 2.27 widać, że odpowiednia linia trendu wyznaczona w kierunku  $y$  jest praktycznie pozioma, co pozostaje w zgodzie z niewielkimi zmianami w średnich wartościach ułamka  $r_{vy}$  w poszczególnych przedziałach odległości epicentralnych.

Analizując zależność ułamka  $r_{WA}$  od odległości epicentralnych  $r_e$  (rys. 2.25, tabela 2.6) zauważono, że wypadkowe przyspieszenia drgań najlepiej przekazują się w przypadku większych odległości ( $r_e > 1500$  m) i wtedy różnice między  $r_{WA}$  i  $r_{WV}$  są najmniejsze.

Zdecydowanie większą różnicę w redukcji maksymalnych wartości wypadkowych prędkości i przyspieszeń drgań obserwuje się w przypadku średnich odległości epicentralnych ( $800 < r_e \leq 1500$ ). Prędkości wypadkowych drgań gruntu przekazują się stosunkowo dobrze na fundament budynku przy dużych odległościach epicentralnych wstrząsów (rys. 2.25). Natomiast najlepiej przekazują się wypadkowe prędkości drgań przy najmniejszych odległościach epicentralnych ( $r_e \leq 800$ ).

Porównując przekazywanie składowych przyspieszeń drgań oraz składowych prędkości drgań stwierdzono, iż w poszczególnych przedziałach  $r_e$  lepiej przekazują się drgania w przypadku prędkości, co potwierdzają odpowiednie wartości średnie ułamków (tabela 2.6). Wartości ułamków  $r$  w przypadku składowych prędkości drgań są od około 1.5 do około 2 razy większe niż w przypadku ułamków  $r$  dla składowych przyspieszeń drgań we wszystkich przedziałach odległości epicentralnej  $r_e$ . Nieco mniejszą różnicę obserwuje się, gdy porównuje się ułamki  $r_{WA}$  i  $r_{WV}$ . Niemniej jednak drgania lepiej przekazują się w przypadku wypadkowych prędkości drgań, niż wypadkowych przyspieszeń drgań.


#### **2.3.4. Wpływ kierunku dotarcia fali na przekazywanie drgań z gruntu na fundament budynku**

Badano również zależność relacji przyspieszeń oraz prędkości (składowych i wypadkowych) drgań fundamentu budynku i odpowiednich drgań gruntu w pobliżu budynku od kierunku propagacji drgań od ogniska wstrząsu górniczego do budynku, a więc analizowano wpływ położenia budynku w stosunku do miejsca wstrząsu górniczego.


Rys. 2.28 poglądowo przedstawia zależności ułamków  $r_{WA}$  i  $r_{WV}$  od współrzędnych sejsmologicznych analizowanych wstrząsów górniczych [40].



a)





b)





Rys. 2.28. Zależność ułamka  $r_{WA}$  (a) i  $r_{WV}$  (b) od współrzędnych sejsmologicznych X i Y analizowanych wstrząsów górniczych [40]

Na rys. 2.29 przedstawiono zależność wartości ułamka  $r_a$  od współrzędnych sejsmologicznych X, Y wszystkich analizowanych wstrząsów górniczych wraz z liniami trendu. Natomiast na rys. 2.30 pokazano wartości ułamka  $r_v$  w funkcji współrzędnych sejsmologicznych X, Y wraz z liniami trendu. Dodatkowo odpowiednio na rys. 2.29 oraz rys. 2.30 przedstawiono te zależności osobno w kierunku x kierunku y.

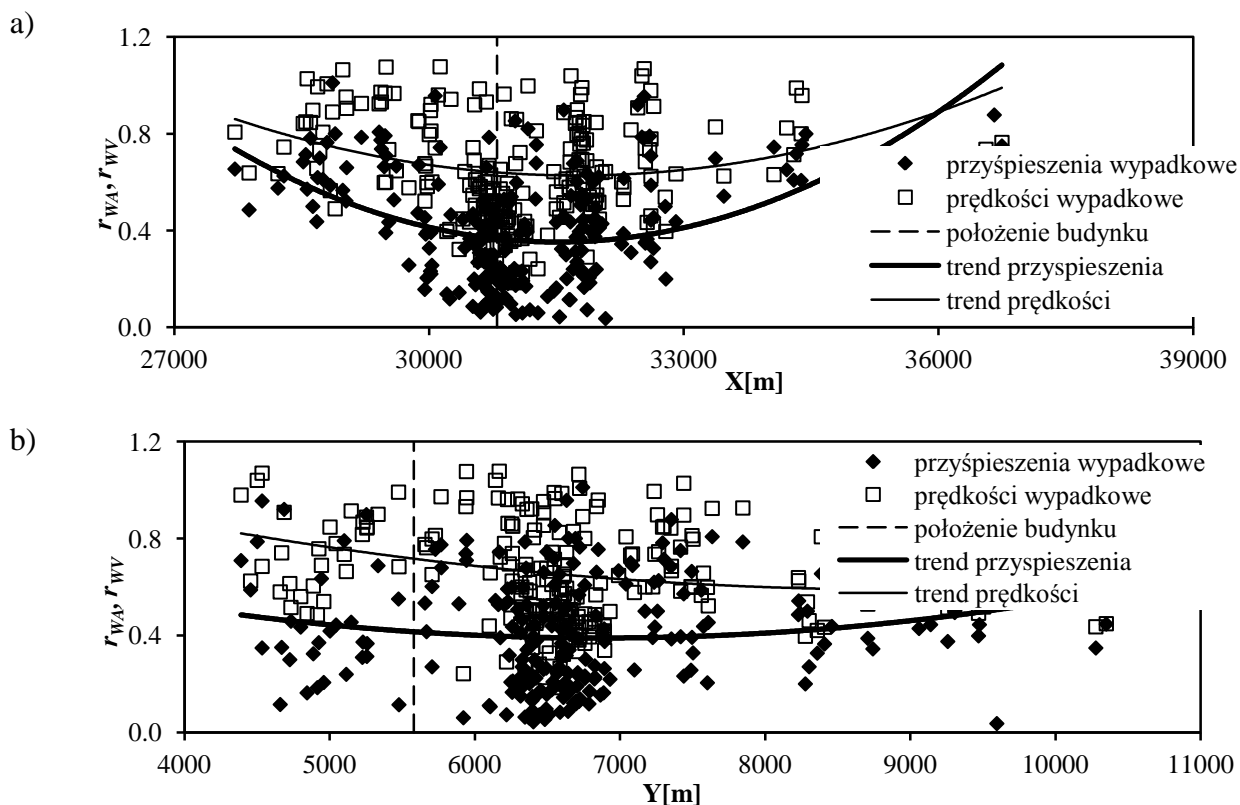
Rys. 2.31 przedstawia zależność ułamków  $r_{WA}$  oraz  $r_{WV}$  od współrzędnych sejsmologicznych X, Y rozważanych wstrząsów górniczych.



Rys. 2.29. Zależność ułamka  $r_a$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów



Rys. 2.30. Zależność ułamka  $r_v$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów



Rys. 2.31. Zależność ułamka  $r_{WA}$  i  $r_{WV}$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów

Tabela 2.7

Zależność średnich wartości ułamków  $r$  od współrzędnej sejsmologicznej X wstrząsów

X [m]	Wartość średnia $r$							
	przyspieszenia				prędkości			
	$r_{axy}$	$r_{ax}$	$r_{ay}$	$r_{wa}$	$r_{vxy}$	$r_{vx}$	$r_{vy}$	$r_{wv}$
do 28399	0,51	0,39	0,64	0,59	0,67	0,54	0,80	0,71
28400 – 29199	0,53	0,41	0,63	0,66	0,78	0,56	0,97	0,85
29200 – 29999	0,48	0,35	0,60	0,54	0,74	0,60	0,87	0,77
30000 – 30799	0,31	0,17	0,44	0,30	0,62	0,42	0,81	0,59
<b>B U D Y N E K</b>								
30800 – 31599	0,32	0,21	0,43	0,31	0,64	0,51	0,79	0,58
31600 – 32399	0,39	0,25	0,52	0,38	0,65	0,49	0,81	0,68
32400 – 33199	0,51	0,41	0,62	0,53	0,67	0,57	0,79	0,71
powyżej 33200	0,55	0,41	0,69	0,70	0,65	0,46	0,85	0,81

Tabela 2.8

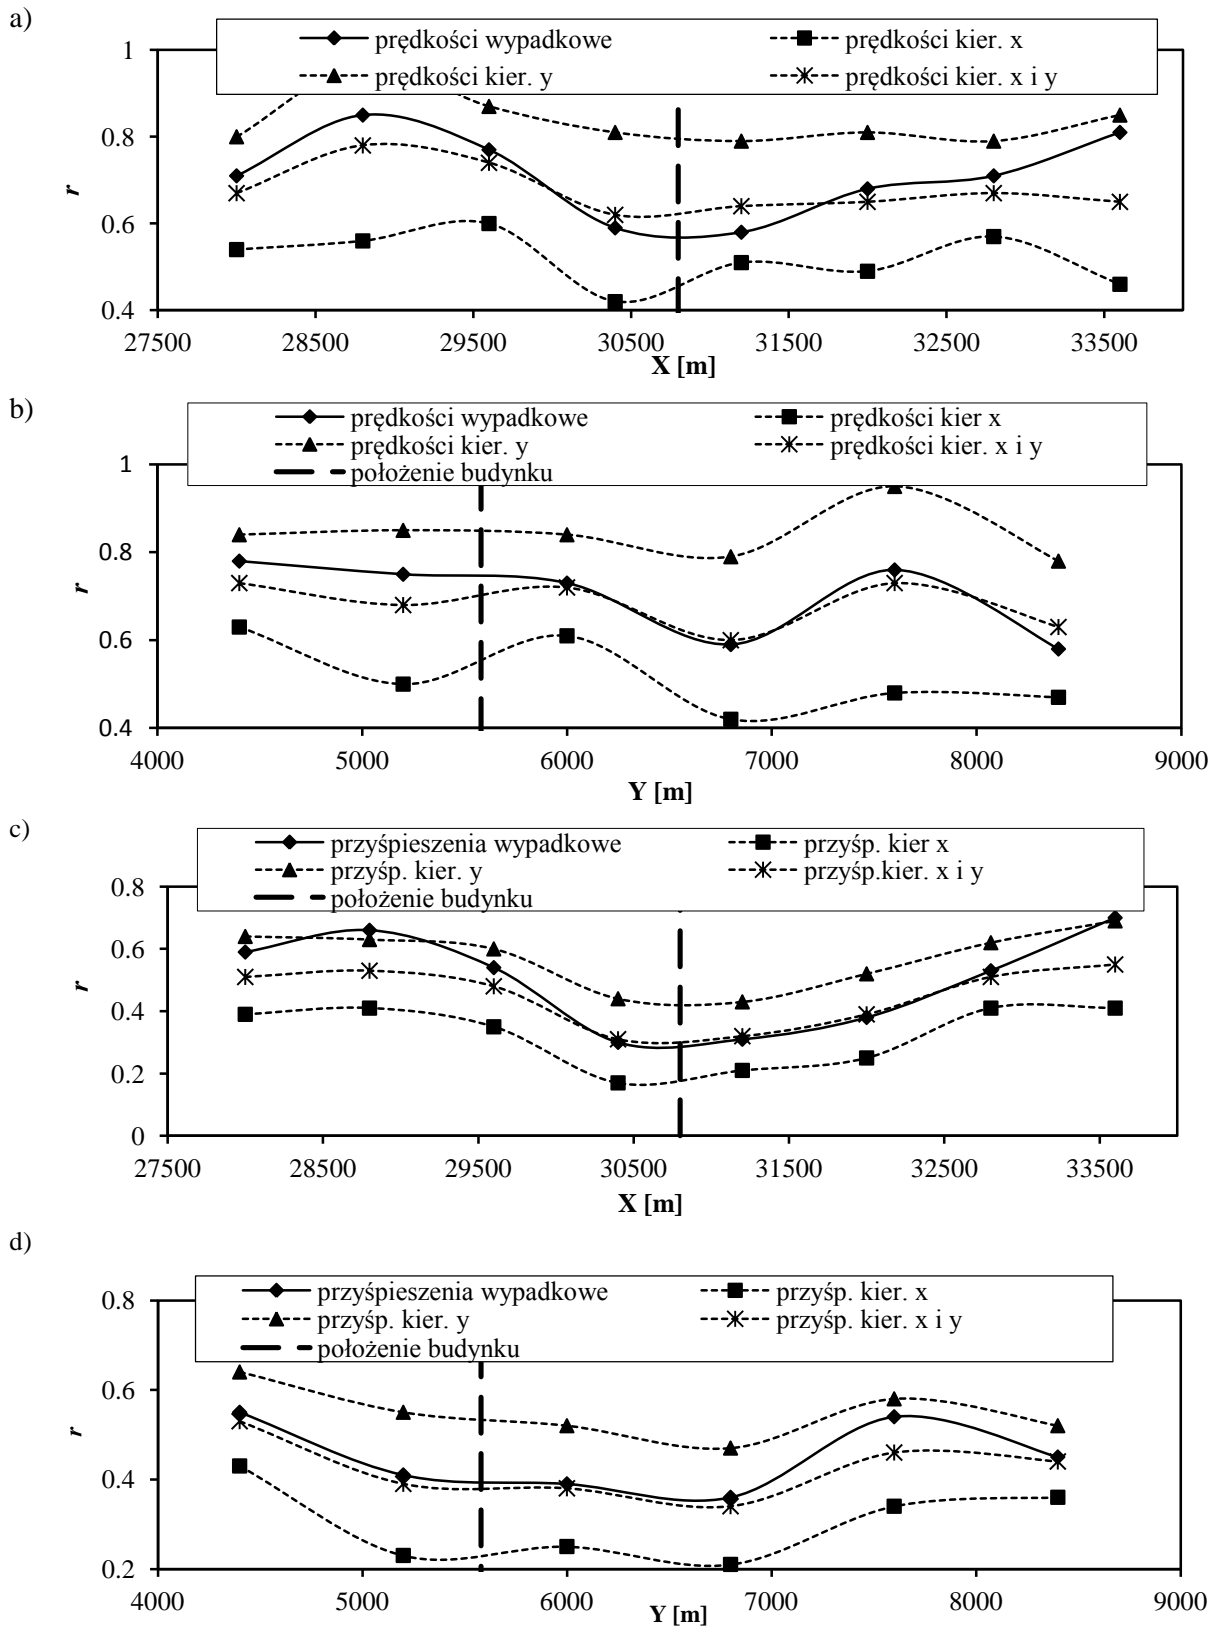
Zależność średnich wartości ułamków  $r$  od współrzędnej seismologicznej  $Y$  wstrząsów

Y [m]	Wartość średnia $r$							
	przyspieszenia				prędkości			
	$r_{axy}$	$r_{ax}$	$r_{ay}$	$r_{wa}$	$r_{vxy}$	$r_{vx}$	$r_{vy}$	$r_{vv}$
do 4799	0,53	0,43	0,64	0,55	0,73	0,63	0,84	0,78
4800 – 5579	0,39	0,23	0,55	0,41	0,68	0,50	0,85	0,75
<b>B U D Y N E K</b>								
5580 – 6399	0,38	0,25	0,52	0,39	0,72	0,61	0,84	0,73
6400 – 7199	0,34	0,21	0,47	0,36	0,60	0,42	0,79	0,59
7200 – 7999	0,46	0,34	0,58	0,54	0,73	0,48	0,95	0,76
Powyżej 8000	0,44	0,36	0,52	0,45	0,63	0,47	0,78	0,58

Analizując przedstawione wykresy stwierdzono duży rozrzut wartości ułamków  $r$ . Widać jednak, że drgania mogą się w różny sposób przekazywać z gruntu na budynek mimo takiej samej bezwzględnej odległości ogniska wstrząsu mierzonej w danym kierunku układu osi seismologicznych (X, Y).

Podobne spostrzeżenia dotyczą średnich wartości wszystkich ułamków  $r$  wyliczanych w odpowiednich „pasmach” współrzędnych seismologicznych o takiej samej szerokości, branych po „obu stronach” budynku zarówno w kierunku współrzędnej seismologicznej X, jak i Y. Wartości te zamieszczono odpowiednio w tabeli 2.7 i tabeli 2.8.

Na rys. 2.32 pokazano przykładowo graficzną ilustrację zależności średnich wartości tych ułamków od współrzędnej X oraz Y w przypadku przekazywania prędkości drgań (rys. 2.32 a, b), oraz od współrzędnej X i Y w przypadku przekazywania przyspieszeń drgań (rys. 2.32 c, d) z gruntu na fundament budynku. Punkty odpowiadające wyliczonym wartościom ułamków z każdej grupy połączono w celu wyraźniejszego pokazania występujących relacji.



Rys. 2.32. Średnie wartości ułamków  $r$  w „pasmach” współrzędnej sejsmologicznej X (a, c) oraz Y (b, d) w przypadku prędkości drgań oraz przyspieszeń drgań

Generalnie można zaobserwować, że drgania wzbudzone wstrząsami górnictwymi, których ognisko ma mniejsze współrzędne sejsmologiczne Y, nieco lepiej przekazują się z gruntu na fundament budynku niż drgania od wstrząsów o współrzędnych sejsmologicznych Y większych. Przeciwna relacja ujawnia się tylko w przypadku najbliższego sąsiedztwa budynku dla składowych drgań w kierunku  $x$  (prędkości i przyspieszeń).

Analizując zależność średnich ułamków  $r_v$  od współrzędnych sejsmologicznych X i Y rozpatrywanych wstrząsów górnictwowych stwierdzono lepsze przekazywanie się drgań w przypadku kierunku  $y$ , co jest zgodne ze wcześniejszymi spostrzeżeniami dotyczącymi wpływu  $E_n$  i  $r_e$  na przekazywanie drgań z podłoża na budynek. W tym przypadku średnie wartości ułamka  $r_v$  przyjmują największe wartości. Można zauważyć, że w najbliższym sąsiedztwie budynku zarówno w przypadku współrzędnych X, jak i Y, największa redukcja składowych prędkości drgań występuje w przypadku kierunku  $x$ . Analogiczne relacje zauważono w przypadku składowych przyspieszeń drgań.

W przypadku analizy wypadkowych prędkości oraz przyspieszeń drgań zauważono, iż w poszczególnych przedziałach współrzędnych sejsmologicznych większa redukcja występuje w przypadku wypadkowych przyspieszeń. Dotyczy to zarówno współrzędnej sejsmologicznej X i współrzędnej Y we wszystkich rozważanych przedziałach.

Przy przekazywaniu drgań z gruntu na budynek, redukcja maksymalnych wartości prędkości drgań jest mniejsza niż redukcja maksymalnych wartości przyspieszeń drgań od tych samych wstrząsów górnictwowych we wszystkich przedziałach współrzędnych sejsmologicznych X i Y.

Z przeprowadzonych analiz danych z badań doświadczalnych w zakresie redukcji maksymalnych wartości wypadkowych oraz składowych przyspieszeń i prędkości drgań wywołanych wstrząsami górnictwowymi przy ich przekazywaniu z gruntu na fundament budynku o średniej wysokości wynika, że kierunek propagacji fali od epicentrum wstrząsu do budynku ma wyraźny wpływ na sposób tego przekazywania. Stwierdzono, że wpływ ten występuje nawet wtedy, gdy inne parametry wstrząsu ( $E_n$ ,  $r_e$ ) są zbliżone.

### **2.3.5. Wpływ maksymalnych wartości (amplitud) drgań gruntu na przekazywanie drgań z gruntu na fundament budynku**

W tabeli 2.9 i tabeli 2.10 zamieszczono średnie wartości ułamka  $r_a$  oraz  $r_{WA}$  w odpowiednich przedziałach maksymalnej wartości (amplitudy) przyspieszenia na gruncie  $a_{gmax}$  oraz  $PGA$ .

Tabela 2.9

Zależność średnich wartości ułamków  $r_a$  od maksymalnych przyspieszeń drgań gruntu  $a_{gmax}$ 


		Wartość średnia $r_a$		
		kierunek		
		x i y	x	y
$a_{gmax}$ [m/s <sup>2</sup> ]	$\leq 300$	0,38	0,25	0,49
	0.301-0.600	0,42	0,29	0,60
	0.601-0.900	0,33	0,25	0,42
	$> 0.900$	0,47	0,35	0,89


Tabela 2.10

Zależność wartości średniej  $r_{WA}$  od maksymalnych wypadkowych przyspieszeń drgań gruntu  $PGA$ 


$PGA$ [m/s <sup>2</sup> ]	Wartość średnia $r_{WA}$	
	$\leq 300$	0,40
0,301 – 0,600	0,43	
0,601 – 0,900	0,39	
$> 0,900$	0,47	

Na rys. 2.33 oraz rys. 2.34 przedstawiono odpowiednio zależność ułamków  $r_{axy}$ ,  $r_{ax}$ ,  $r_{ay}$  oraz  $r_{WA}$  w zależności od maksymalnego przyspieszenia na gruncie  $a_{gmax}$  oraz maksymalnego wypadkowego przyspieszenia drgań gruntu  $PGA$ . Natomiast na rys. 2.35 oraz rys. 2.36 przedstawiono zależność odpowiednich wartości ułamków  $r$  od maksymalnej prędkości drgań gruntu  $v_{gmax}$  oraz maksymalnej wypadkowej prędkości drgań gruntu  $PGV$ .


Rys. 2.33. Zależność ułamka  $r_a$  od maksymalnego przyspieszenia drgań gruntu  $a_{gmax}$



Rys. 2.34. Zależność  $r_{WA}$  od maksymalnej wartości wypadkowego przyspieszenia drgań gruntu  $PGA$



Rys. 2.35. Zależność ułamka  $r_v$  od maksymalnej prędkości drgań gruntu  $v_{gmax}$



Rys. 2.36. Zależność  $r_{WV}$  od maksymalnej wartości wypadkowej prędkości drgań gruntu  $PGV$



Można zauważyć, że średnio biorąc (tabela 2.9 oraz rys. 2.33) składowe przyspieszenia drgań gruntu przekazują się najlepiej na fundament budynku w przypadku największych przyspieszeń na gruncie ( $a_{gmax} > 0,900 \text{ m/s}^2$ ). Stwierdzono, że redukcja przyspieszenia w przypadku kierunku  $y$  jest zdecydowanie mniejsza niż w kierunku  $x$ .


Można zauważyć, że średnio biorąc, redukcja maksymalnego wypadkowego przyspieszenia drgań fundamentu budynku w stosunku do drgań gruntu jest najmniejsza dla  $PGA$  z przedziału  $0,301 - 0,600 \text{ [m/s}^2]$  i większego od  $0,900 \text{ [m/s}^2]$ .

Stwierdzono (rys. 2.35), że redukcja składowych prędkości drgań fundamentu w poszczególnych kierunkach jest wyraźnie mniejsza w przypadku większych prędkości drgań gruntu. Niemniej jednak redukcja drgań w przypadku tych samych prędkości drgań gruntu jest zdecydowanie większa w kierunku poprzecznym  $x$  budynku niż w kierunku podłużnym  $y$ .


Analogicznie jak w przypadku składowych prędkości drgań redukcja wypadkowych prędkości drgań gruntu przy przekazywaniu ich na fundament budynku jest większa w przypadku mniejszych wypadkowych prędkości drgań gruntu (rys. 2.36).

### 2.3.6. Wpływ dominujących częstotliwości drgań gruntu na przekazywanie drgań z gruntu na fundament budynku

Na rys. 2.37 i rys. 2.38 odpowiednio przedstawiono zależność ułamków  $r_a$  oraz  $r_v$  od dominujących częstotliwości drgań gruntu (odpowiednio: przyspieszeń i prędkości).



Rys. 2.37. Zależność ułamka  $r_a$  od dominujących częstotliwości na gruncie  $f_{1ga}$



Rys. 2.38. Zależność ułamka  $r_v$  od dominujących częstotliwości na gruncie  $f_{1gv}$

Analizując zależność ułamka  $r_a$  (rys. 2.37) od dominujących częstotliwości przyspieszeń drgań gruntu stwierdzono, że przyspieszenia lepiej przekazują się z gruntu na fundament budynku w przypadku kierunku  $y$ . Natomiast największa redukcja przyspieszeń drgań ma miejsce w przypadku kierunku  $x$ . Przyspieszenia drgań z gruntu na fundament budynku przekazują się lepiej w przypadku mniejszych dominujących częstotliwości ( $<10\text{Hz}$ ) we wszystkich analizowanych przypadkach tj. kierunku  $x$ , kierunku  $y$  oraz równocześnie kierunku  $x$  i  $y$ .

Analogiczną sytuację zaobserwowano w przypadku redukcji składowych prędkości drgań (rys. 2.38) w zależności od dominujących częstotliwości prędkości drgań gruntu  $f_{1gv}$ . Stwierdzono, że prędkości drgań najlepiej przekazują się z gruntu na fundament budynku, tak samo jak w przypadku przyspieszeń drgań, w zakresie mniejszych częstotliwości drgań gruntu.

Również w przypadku prędkości drgań zauważono, iż największa redukcja występuje w przypadku kierunku  $x$ , dla którego uzyskano najmniejsze wartości ułamków  $r_{vx}$ .

Analizując linie trendu w przypadku składowych przyspieszeń oraz prędkości drgań stwierdzono, że zarówno w przypadku kierunku  $x$ , kierunku  $y$ , oraz łącznie kierunku  $x$  i  $y$ , lepiej przekazują się z gruntu na fundament budynku prędkości drgań w całym zakresie dominujących częstotliwości prędkości drgań gruntu.


### 2.3.7. Podsumowanie

Określenie sposobu przekazywania drgań z gruntu na fundament budynku pięciokondygnacyjnego w zakresie redukcji maksymalnych składowych oraz wypadkowych przyspieszeń i prędkości drgań poziomych stwarza wiele trudności z uwagi na jego niejednoznaczność. Analizując wyniki pomiarów drgań wywołanych wstrząsami górnictwami stwierdza się duży „rozrzut” wartości ułamków  $r$ . Na podstawie analiz tych wyników badań


doświadczalnych nie jest możliwe wyznaczenie dokładnej zależności między odpowiednimi uławkami  $r$ , a podstawowymi parametrami wstrząsów górniczych, takimi jak energia wstrząsów górniczych  $En$ , odległość epicentralna  $r_e$ , współrzędne sejsmologiczne X i Y, a także parametrami drgań takimi jak maksymalne przyspieszenia drgań gruntu ( $a_{gmax}$ ,  $PGA$ ), maksymalne prędkości drgań gruntu ( $v_{gmax}$ ,  $PGV$ ), dominujące częstotliwości drgań gruntu oraz kierunek drgań równoległy do osi poprzecznej  $x$  i osi podłużnej  $y$  budynku, choć można dopatrywać się ich wpływu na te relacje. Trudno jest również precyzyjnie podać jak duży wpływ na dokładność prognozy przekazywania drgań z podłoża na fundament budynku ma uwzględnienie każdego z tych parametrów, czyli określić jak istotny jest ich udział w wielkości redukcji maksymalnej amplitudy drgań fundamentu budynku w stosunku do maksymalnej amplitudy drgań gruntu wzbudzanych wstrząsami górniczymi.

Na rys. 2.39 pokazano gęstości prawdopodobieństwa rozkładu normalnego wartości ułamek  $r_a$  wyliczanych w przypadku przekazywania składowych przyspieszeń drgań osobno w kierunku  $x$ , osobno w kierunku  $y$ , łącznie w kierunku  $x$  i  $y$  oraz w przypadku drgań wypadkowych.

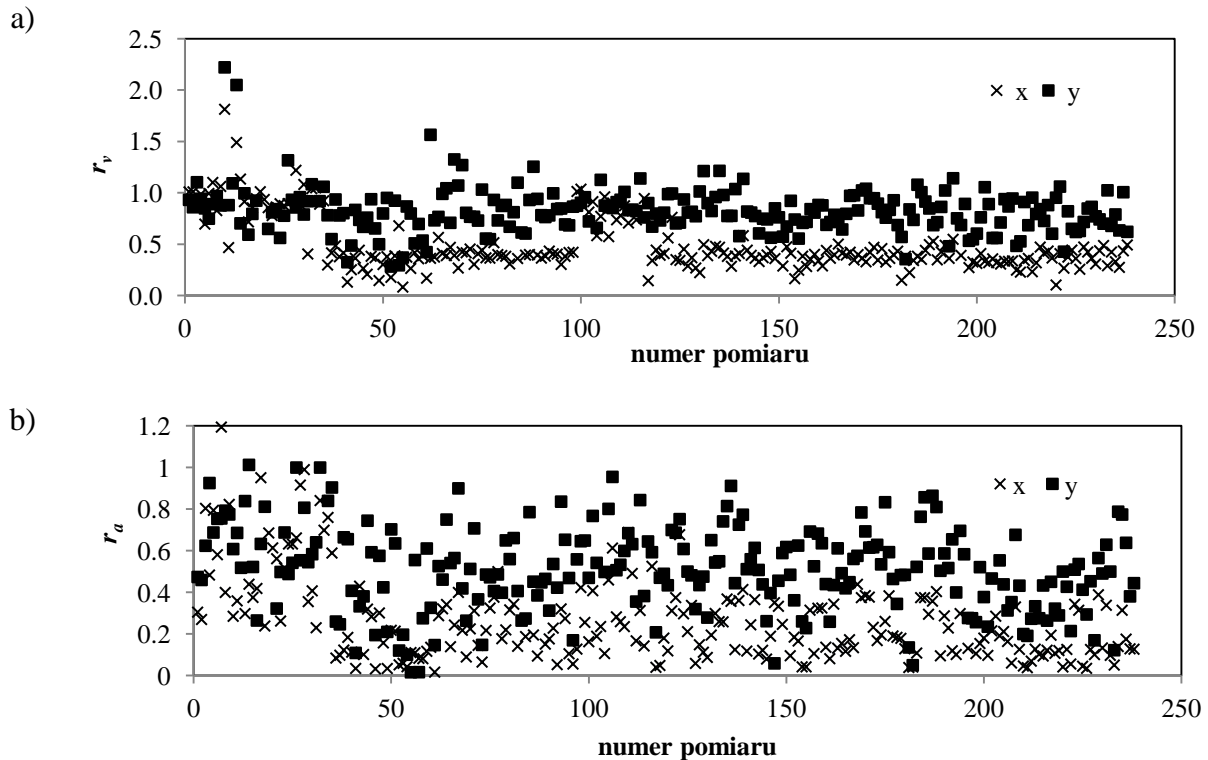
Dodatkowo na rys. 2.40 porównano gęstości prawdopodobieństwa ułamek  $r_{WA}$ ,  $r_{WV}$  oraz podano wartości średnie tych ułamek. Ułamek  $r_{WVsr}$  jest ok. 1.5 razy większy niż ułamek  $r_{WAsr}$ . Zatem również średnie wartości ułamek  $r_{WA}$ ,  $r_{WV}$  wskazują, iż drgania lepiej przekazują się z gruntu na fundament budynku w przypadku wypadkowych prędkości.



Rys. 2.39. Gęstość prawdopodobieństwa rozkładu normalnego wartości ułamka  $r_a$  w przypadku składowych oraz wypadkowych przyspieszeń drgań



Rys. 2.40. Gęstość prawdopodobieństwa rozkładu normalnego wartości ułamków  $r_{WA}$  i  $r_{WV}$



Rys. 2.41. Porównanie wartości ułamków  $r_a$  (a) oraz  $r_v$  (b) w kolejnych pomiarach w zależności od kierunku drgań

Różny stopień redukcji składowych maksymalnych prędkości oraz maksymalnych składowych przyspieszeń drgań przy przekazywaniu ich z gruntu na fundament budynku w obu analizowanych kierunkach widać wyraźnie w zestawieniu pokazanym na rys. 2.41 a, b. Praktycznie mniejszą wartość ułamka  $r$  wyznaczono w kierunku poprzecznym  $x$  w przypadku niemal wszystkich pomiarów zarówno w przypadku prędkości, jak i przyspieszeń drgań. Zatem większa redukcja drgań występuje kierunku  $x$ , niż kierunku  $y$ .

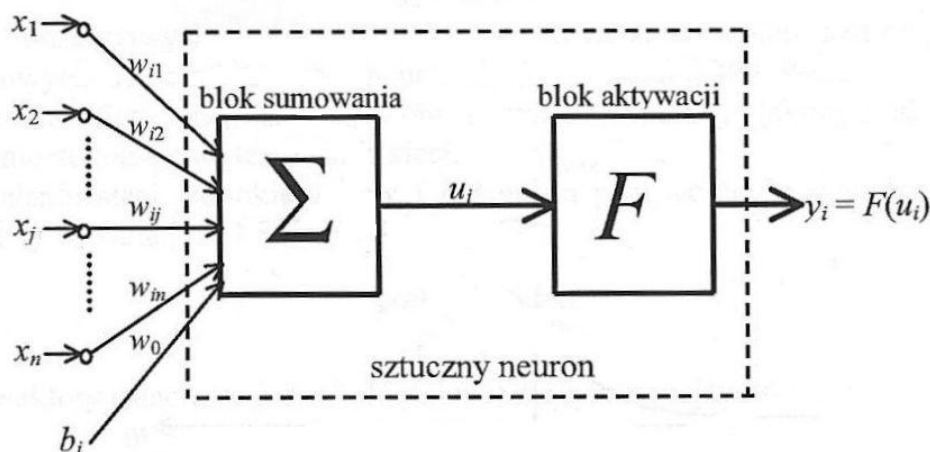
Stwierdzono, że wszystkie analizowane drgania (składowe i wypadkowe) lepiej przekazują się z gruntu na fundament budynku w przypadku prędkości drgań, niż w przypadku przyspieszeń drgań.

### 3. WYBRANE ZAGADNIENIA TEORII SZTUCZNYCH SIECI NEURONOWYCH (SSN)

#### 3.1. Wiadomości wstępne

Komórka nerwowa zwana neuronem jest podstawową częścią systemu nerwowego i jest odpowiedzialna za przesyłanie, przetwarzanie oraz wykorzystanie informacji przebiegających w sieciach neuronowych [62]. W oparciu o zasadę działania rzeczywistego neuronu stworzono szereg modeli matematycznych uwzględniających w większym lub mniejszym stopniu własności rzeczywistej komórki neuronowej [62, 87]. Sztuczne sieci neuronowe (SSN) to model obliczeniowy powstały na bazie wiedzy o działaniu układu nerwowego żywych organizmów [62, 87].

Sieć wielowarstwowa jednokierunkowa składa się ze zbioru neuronów poukładanych w warstwach: wejściowej, ukrytej i wyjściowej. Sygnał wyjściowy każdego neuronu jest funkcją jego sygnałów wejściowych. Ma on skończoną liczbę wejść oraz jedno wyjście, por. rys. 3.1 [85]. Jednostka przetwarzająca składa się z bloku sumowania i bloku aktywacji [62, 85].



Rys. 3.1. Model sztucznego neuronu [85]

W modelu sztucznego neuronu z rys. 3.1 zastosowano następujące oznaczenia:

$x = \{x_1, x_2, \dots, x_j, \dots, x_N\}$	– wektor wejścia,	
$x_j, j = 1, \dots, n$	– sygnały wejściowe,	
$w_{ij}$	– element wektora wag,	
$b_i$	– bias (wartość progowa),	(3.1)
$u_i$	– potencjał neuronu,	
$F(u_i)$	– funkcja aktywacji.	

Obliczany w bloku sumowania potencjał neuronu  $u_i$  przyjmuje postać [62]:

$$u_i = \sum_{j=1}^n w_{ij}x_j + b_i \quad (3.2)$$


W bloku aktywacji potencjał  $u_i$  przekształcany jest w sygnał wyjścia  $y_i$  za pomocą funkcji aktywacji  $F$ :

$$y_i = F(u_i). \quad (3.3)$$

W obliczeniach z wykorzystaniem sztucznych sieci neuronowych używane są funkcje aktywacji różnego typu tj. liniowa, progowa unipolarna, progowa binarna, sigmoidalna unipolarna, sigmoidalna bipolarna, Gaussa [62]. W niniejszej pracy zastosowano sigmoidalną unipolarną (logistyczną) funkcję aktywacji. Jest to bardzo często stosowana funkcja, szczególnie w zagadnieniach dynamiki konstrukcji [37]. Przyjęcie sigmoidalnej funkcji aktywacji pozwala na zastosowanie w uczeniu sieci algorytmów gradientowych, wymagających ciągłości funkcji celu. Funkcja unipolarna przyjmowana jest w postaci:

$$F(u_i) = \frac{1}{1 + \exp(-u_i)} \in (0,1) \quad (3.4)$$

Na rys. 3.2 przedstawiono wykres funkcji sigmoidalnej unipolarnej.



Rys. 3.2. Sigmoidalna unipolarna (logistyczna) funkcja aktywacji  $F(u_i)$  [85]

Ważną cechą funkcji sigmoidalnej jest jej różniczkowalność. W przypadku funkcji unipolarnej otrzymuje się:

$$F' = \frac{\partial F}{\partial u_i} = F(u_i) \cdot (1 - F(u_i)). \quad (3.5)$$

Ze wzoru (3.4) widać, że nie ma możliwości osiągnięcia przez funkcje sigmoidalne minimalnej oraz maksymalnej wartości. Należy przyjąć, że pełny stopień aktywacji neuronów zostanie osiągnięty dla wartości około 0.9, a pełny stan zerowy w przybliżeniu dla 0.1 [58, 62, 85]. W związku z tym, w przypadku używania logistycznej funkcji aktywacji konieczne jest przeskalowanie wszystkich parametrów wyjściowych sieci neuronowej tak, aby mieściły się w przedziale [0.1, 0.9]. Często również stosuje się skalowanie parametrów wejścia sieci w celu poprawienia procesu uczenia sieci neuronowej [37, 58].

Sieć neuronowa o jednym kierunku przepływu sygnału należy do najpopularniejszych w zastosowaniach typów sieci [62]. Działanie takiej sieci polega na przetworzeniu sygnałów wejścia na sygnały wyjścia.

$$\mathbf{x}_{(Nx1)}^{(p)} \rightarrow \mathbf{y}_{(Mx1)}^{(p)}, \quad (3.6)$$

gdzie wektory przyjmują postać:

$$\mathbf{x}_{(Nx1)}^{(p)} = \{x_1^{(p)}, \dots, x_N^{(p)}\}, \quad \mathbf{y}_{(Mx1)}^{(p)} = \{y_1^{(p)}, \dots, y_M^{(p)}\}, \quad (3.7)$$

gdzie:

- $N$  – liczba parametrów w wektorze wejścia,
- $M$  – liczba parametrów w wektorze wyjścia.

Uczenie, walidacja oraz testowanie oparte jest na wykorzystaniu zbioru wzorców, czyli par wektorów wejściowych oraz wyjściowych o znanych elementach składowych [62]:

$$\mathbb{Q} = \{(\mathbf{x}, \mathbf{z})^p; p = 1, \dots, Q\} \quad (3.8)$$

gdzie:

- $\mathbf{x}$  – wektor wejścia,
- $\mathbf{z}$  – wektor wyjścia wartości oczekiwanych,
- $Q$  – liczba wszystkich wzorców.

W celu zaprojektowania sztucznej sieci neuronowej dzieli się zbiór danych na trzy podzbiory: uczący ( $\mathbb{L}$ ), walidujący ( $\mathbb{V}$ ) oraz testujący ( $\mathbb{T}$ ) [63]. W przypadku uczenia sieci oblicza się wartości parametrów sieci przy zastosowaniu konkretnego algorytmu uczenia. Następnie sieć podlega testowaniu [62].



$$\mathbb{L} = \{(\mathbf{x}, \mathbf{z})^p; p = 1, \dots, L\} \quad \mathbb{V} = \{(\mathbf{x}, \mathbf{z})^p; p = 1, \dots, V\} \quad \mathbb{T} = \{(\mathbf{x}, \mathbf{z})^p; p = 1, \dots, T\} \quad (3.9)$$

gdzie:

- $L$  – liczba wzorców uczących,
- $V$  – liczba wzorców walidujących,
- $T$  – liczba wzorców testujących.

Wprowadzając do sieci sygnał  $\mathbf{x}^{(p)}$  otrzymuje się wyliczony wektor wyjścia  $\mathbf{y}^{(p)}$ , zamiast wartości oczekiwanej  $\mathbf{z}^{(p)}$ . Uczenie sieci ma na celu wyznaczenie wartości wag na połączeniach neuronów poszczególnych warstw tak, aby uzyskać na wyjściu sieci wartości wektora  $\mathbf{y}^{(p)}$  równające się z wystarczającą dokładnością wartościom oczekiwany  $\mathbf{z}^{(p)}$ , przy zadanym wektorze wejścia  $\mathbf{x}^{(p)}$  [62]. Uczenie polega na aktualizacji wektora wag zgodnie ze wzorem [57]:

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad (3.10)$$

gdzie:

- $i$  – numer rozpatrywanej komórki sieci neuronowej,
- $j$  – numer wejścia do  $i$ -tej komórki,
- $k$  – krok iteracyjny.

Jako miarę błędu aproksymacji neuronowej stosowano błąd średniokwadratowy (*Mean Square Error*)  $MSE$ , który w przypadku sieci z jednoelementowym wektorem wyjścia przyjmuje postać [58]:

$$MSE(Q) = \frac{1}{Q} \sum_{p=1}^Q (z^{(p)} - y^{(p)})^2, \quad (3.11)$$

gdzie:

$Q = L, V, T$  – liczba wzorców w zbiorze uczącym ( $L$ ), walidującym ( $V$ ) i testującym ( $T$ ),

oraz błędy względne  $ep$  i błędy bezwzględne  $Ep$ :

$$ep = \left| 1 - y^{(p)} / z^{(p)} \right| \cdot 100\%, \quad (3.12)$$

$$Ep = z^{(p)} - y^{(p)}. \quad (3.13)$$

Do oceny dokładności przeprowadzonych obliczeń wykorzystano również tzw. procent sukcesu (success ratio)  $SR$  [%] w zależności od błędu względnego  $ep$  [%].  $SR$  określa jaki procent wzorców uzyskano z predykcji neuronowej z błędem nie większym niż  $ep$ .

W niniejszej pracy do prognozowania przekazywania drgań z gruntu na fundament budynku zaproponowano wykorzystanie standardowych sieci neuronowych typu wstecznej propagacji błędu, sieci neuronowych z regularyzacją oraz bayesowskich sieci neuronowych. W celu zwiększenia dokładności obliczeń projektowano również kaskadowe sztuczne sieci neuronowe.

## 3.2. Zastosowane sztuczne sieci neuronowe

### 3.2.1. Sieci neuronowe typu wstecznej propagacji błędu (WPB)

Sieciami najczęściej stosowanymi w analizie konstrukcji i w inżynierii lądowej są sieci jednokierunkowe ze wsteczną propagacją błędu (WPB) [22, 62, 86]. Stanowią one ponad 80% wszystkich zastosowań sieci [86].


Algorytm propagacji wstecznej określa sposób doboru wag w sieci neuronowej przy wykorzystaniu gradientowych metod optymalizacji. Uczenie z zastosowaniem ww. algorytmu jest kilkufazowe. W fazie pierwszej dochodzi do wyliczenia wartości sygnałów poszczególnych neuronów sieci przy wprowadzeniu zbioru danych. Dla danego wektora wejścia obliczane są wartości wektora wyjścia oraz suma kwadratów różnic między aktualnymi wartościami sygnałów wyjściowych sieci, a wartościami zadanymi. Natomiast w drugiej fazie algorytmu następuje minimalizacja tej funkcji. Zatem przyrost  $\Delta w_{ij}$  może być obliczany w różny sposób. W przypadku ciągłych funkcji aktywacji powszechnie stosuje się metodę gradientową największego spadku błędu średniokwadratowego  $MSE(Q)$  [22, 62, 86]:

$$\Delta w_{ij}^{(p)} = -\eta \cdot \frac{\partial MSE(Q)^{(p)}}{\partial w_{ij}^{(p)}}, \quad (3.14)$$

gdzie:  $\eta$  – parametr uczenia.

Zgodnie z metodą gradientową największego spadku, warunkiem koniecznym dla minimum lokalnego jest zerowanie się pochodnych:  $(\partial MSE / \partial w_{ij}) = 0$ .

Przedstawiona metoda uczenia uznawana jest jako klasyczna metoda uczenia sieci typu wstecznej propagacji błędu. Na rys. 3.3 przedstawiono schemat takiej sieci [85].



Rys. 3.3. Schemat propagacji sygnałów i błędów w sieci typu WPB [85]

W algorytmie propagacji wstecznej można wyróżnić następujące etapy uczenia sztucznej sieci neuronowej [63]:

1. Analiza sieci neuronowej o zwykłym kierunku przepływu sygnałów przy założeniu sygnałów wejściowych sieci równych elementom aktualnego wektora  $\mathbf{x}$ . W wyniku analizy otrzymuje się wartości sygnałów wyjściowych neuronów warstw ukrytych oraz warstwy wyjściowej, a także odpowiednie pochodne  $dF(u_i)/du_i$  funkcji aktywacji w poszczególnych warstwach.
2. Utworzenie sieci propagacji wstecznej przez odwrócenie kierunków przepływu sygnałów, zastąpienie funkcji aktywacji przez ich pochodne, a także podanie do byłego wyjścia (obecnie wejścia) sieci wymuszenia w postaci odpowiedniej różnicy między wartością aktualną i żadaną. Dla tak utworzonej sieci należy obliczyć wartość odpowiednich różnic wstecznych.
3. Uaktualnienie wag (uczenie sieci) odbywa się na podstawie wyników uzyskanych w punktach 1 i 2 dla sieci zwykłej i sieci o propagacji wstecznej.
4. Proces opisany w punktach 1, 2, 3 należy powtórzyć dla wszystkich wzorców uczących, kontynuując go do chwili spełnienia warunku zatrzymania algorytmu.

W niniejszej pracy zdecydowano się na wykorzystanie sieci jednokierunkowej ze wsteczną propagacją błędów z algorytmem uczenia *Levenberga – Marquardta* (LM) [98] i sigmoidalną unipolarną (logistyczną) funkcją aktywacji w warstwie ukrytej.

### 3.2.2. Sztuczne sieci neuronowe z regularyzacją

Podstawowym celem uczenia standardowej sztucznej sieci neuronowej jest minimalizacja funkcji błędów średniokwadratowych, który wyliczany jest w przypadku jednoelementowego wektora wyjścia wg wzoru (3.11) [57, 100].

W przypadku uczenia z regularyzacją obliczenia wykonuje się z użyciem regularyzatora wag:

$$MSW = \frac{1}{n} \sum_{j=1}^n w_j^2, \quad (3.15)$$

gdzie:

$n$  – liczba uogólnionych wag.

Błąd  $MSW$  pełni rolę funkcji kary we wzorze na błąd regularyzacji:

$$MSEREG = \gamma MSE + (1-\gamma)MSW, \quad (3.16)$$

gdzie:

$\gamma$  – jest współczynnikiem regularyzacji.

Współczynnik regularyzacji  $\gamma$  przyjmuje wartości z przedziału (0, 1). W przypadku, gdy współczynnik  $\gamma$  przyjmuje wartość „1” wówczas mamy do czynienia ze standardową sztuczną siecią neuronową. Użycie tej funkcji powoduje lepszą wydajność, co prowadzi do zmniejszania wartości wag w sieci i mniej prawdopodobne jest ponad przyleganie (overfitting) aproksymacji neuronowej w czasie uczenia sieci [100].

### 3.2.3. Bayesowskie sieci neuronowe

Podstawowym celem sieci neuronowej typu wstecznej propagacji jest minimalizacja funkcji błędu sieci w celu wyznaczenia wag  $w_{ij}$  [20, 87]. Widocznym niedostatkim takiej sieci jest jej deterministyczny charakter [87], stąd podjęto próbę wykorzystania jeszcze jednego typu sieci neuronowych, a mianowicie tzw. sieci bayesowskich [20, 88].

Metody oparte na twierdzeniu sformułowanym przez Bayesa odgrywają znaczącą i rosnącą ostatnio rolę np. w sztucznej inteligencji [87]. Na początku lat 90 – tych pojawiła się koncepcja łączenia SSN z wnioskowaniem bayesowskim BI (Bayesian Inference) [20]. Wzór Bayesa stanowi podstawę teorii i algorytmów różnych wnioskowań probabilistycznych, w tym bayesowskiego algorytmu uczenia [5, 87]. BI opiera się na twierdzeniu Bayesa, wyrażanym przez prawdopodobieństwo warunkowe  $p(A|B)$ . Jest to wartość ‘a posteriori’, obliczana za pomocą nie tylko zmiennej losowej  $A$ , występującej w prawdopodobieństwie ‘a priori’  $p(A)$ , ale też przez dodatkową wiedzę zawartą w zmiennej losowej  $B$ , która może odpowiadać np. danym pomiarowym. Łączenie BI z SSN doprowadziło do sformułowania obliczeniowego modelu hybrydowego, nazwanego bayesowską siecią neuronową BSN (Bayesowska Sieć Neuronowa). Sieć BSN łączy komponenty (SSN, BI) o komplementarnych właściwościach. Oznacza to radykalną zmianę metody uczenia, tj. przejście do nieiteracyjnej metody marginalizacji zmiennych (całkowanie odpowiednich funkcji, występujących w twierdzeniu Bayesa, w przestrzeniach tych zmiennych) [5, 91].

W bayesowskim modelu SSN wagi, wektor wejścia oraz wyjście SSN są przyjęte jako zmienne losowe. Działanie sieci bayesowskich oparte jest na twierdzeniu Bayesa dla gęstości prawdopodobieństwa warunkowego:

$$p(\mathbf{w}|\mathbf{X}, \mathbf{z}, \alpha, \beta) = \frac{p(\mathbf{z}|\mathbf{X}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha)}{p(\mathbf{z}|\mathbf{X}, \alpha, \beta)} \quad (3.17)$$

Treść twierdzenia Bayesa odnosi się do obliczania wartości gęstości prawdopodobieństwa ‘a posteriori’ znając gęstość ‘a priori’ oraz wprowadzając dodatkową wiedzę przez zmienną  $\mathbf{X}$ . W równaniu (3.17)  $p(\mathbf{w}|\alpha)$  jest gęstością wcześniejszą (*prior*), która reprezentuje naszą wiedzę o wagach przed tym jak jakiegokolwiek dane są zebrane,  $p(\mathbf{z}|\mathbf{X}, \mathbf{w}, \beta)$  jest funkcją wiarygodności, która jest prawdopodobieństwem pojawiających się danych dających wagi  $\mathbf{w}$ . Natomiast  $p(\mathbf{z}|\mathbf{X}, \alpha, \beta)$  jest czynnikiem normalizującym, który gwarantuje, że całkowite prawdopodobieństwo jest 1 [20].

Mianownik w równaniu (3.18) przyjmuje postać

$$p(\mathbf{z}|\mathbf{X}, \alpha, \beta) = \int p(\mathbf{z}|\mathbf{X}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha)d\mathbf{w} \quad (3.18)$$

W powyższych równaniach  $p$  oznacza rozkład prawdopodobieństwa,  $\mathbf{X}$  to zbiór wzorców z wejściami  $\mathbf{X} = \{\mathbf{x}^n\}_{n=1}^N$  i wyjściami  $\mathbf{z} = \{\mathbf{z}^n\}_{n=1}^N$ ,  $\alpha$  i  $\beta$  to hiperparametry, natomiast  $\mathbf{w}$  jest wektorem sieci neuronowej. Wówczas funkcję błędu można przedstawić w następującej postaci [20]:

$$F(\mathbf{w}) = \beta E_D(\mathbf{w}) + \alpha E_W(\mathbf{w}) = \frac{\beta}{2} \sum_{n=1}^N \{z^n - y(x^n; \mathbf{w})\}^2 + \frac{\alpha}{2} \sum_{i=1}^W w_i^2 \quad (3.19)$$

gdzie:

$\alpha E_W(\mathbf{w})$  – czynnik regularyzacyjny.

### 3.2.4. Kaskadowe sztuczne sieci neuronowe

W celu uzyskania lepszych przybliżeń neuronowej predykcji, zdecydowano się na zastosowanie również kaskadowych sieci neuronowych (KSN) [89, 90]. Obliczenia przy pomocy kaskadowych sieci neuronowych sprowadzają się do wykonania zabiegu numerycznego polegającego na wykorzystaniu wyliczonych wartości prognozowania z poprzedniego kroku kaskady w kolejnym kroku poprzez wprowadzenie tej wartości do wektora wejściowego.

W pierwszym kroku ( $i=1$ ) kaskadowej sztucznej sieci ustalana jest architektura sieci neuronowej (liczba neuronów w warstwie ukrytej), poprzez wykonanie obliczeń z użyciem sztucznej sieci neuronowej dowolnego typu. W niniejszej pracy zdecydowano się na

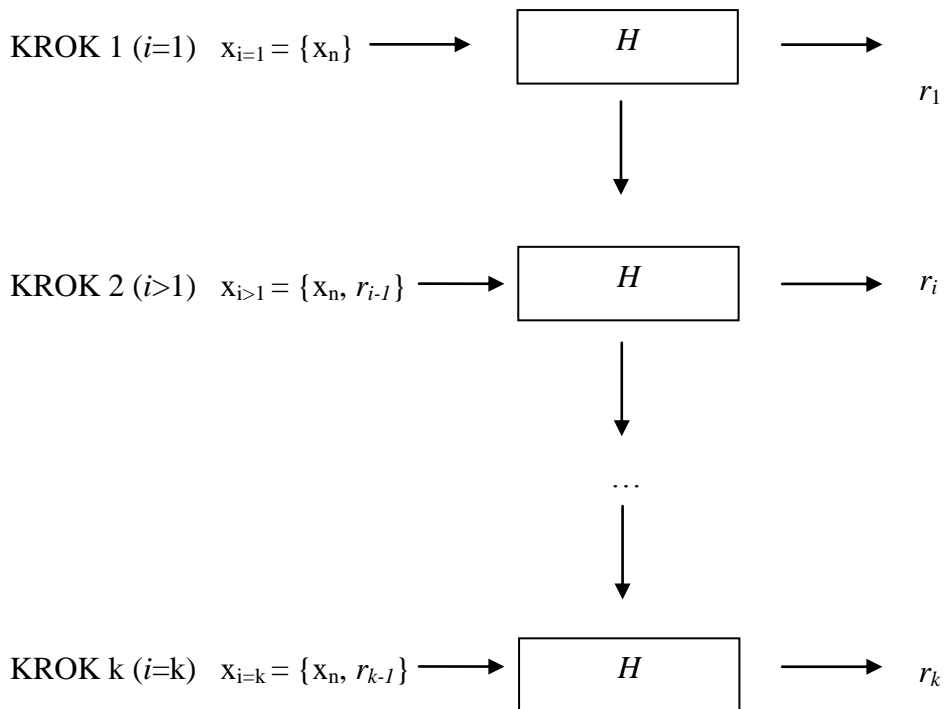
zastosowanie sieci ze wsteczną propagacją błędów, sigmoidalną unipolarną funkcją aktywacji oraz algorytmem uczenia Levenberga – Marquadta. Zaproponowano następujące kolejne kroki sieci kaskadowej:

- Krok 1 ( $i=1$ ): {początkowe parametry wejściowe sieci neuronowej} –  $H - r_1$
- Krok  $i$  - ty ( $i>1$ ): {początkowe parametry wejściowe sieci neuronowej,  $r_{i-1}$ } –  $H - r_i$

gdzie

- $i$  – numer cyklu,  
 $H$  – liczba neuronów w warstwie ukrytej,  
 $r$  – parametr wyjścia sieci neuronowej.

Na rys. 3.4 schematycznie przedstawiono sposób działania kaskadowej sztucznej sieci neuronowej.



Rys. 3.4. Schemat działania zaproponowanej kaskadowej sztucznej sieci neuronowej

Należy zauważyć, iż liczba neuronów w warstwie ukrytej ( $H$ ) jest dobierana w pierwszym kroku kaskadowej sieci neuronowej, a następnie wykorzystywana w kolejnych krokach. W każdym kolejnym kroku – zaczynając od drugiego – liczba parametrów w wektorze wejścia rośnie, ze względu na jego uzupełnienie wartością wyliczoną w kroku poprzedzającym.

## 4. NEURONOWE PROGNOZOWANIE PRZKAZYWANIA DRGAŃ OD WSTRZĄSÓW GÓRNICZYCH Z PODŁOŻA NA FUNDAMENT BUDYNKU

### 4.1. Uwagi wstępne

Z analizy wyników badań doświadczalnych widać, że określenie precyzyjnej zależności ułamków  $r$  od parametrów charakteryzujących wstrząsy górnicze, a więc ocena przekazywania drgań pochodzenia górniczego z gruntu na budynek o średniej wysokości jest bardzo trudna ze względu na pojawiające się niejednoznaczności oraz duży rozrzut wartości ułamków  $r$ .

Wykorzystując wyniki badań doświadczalnych, podjęto próbę zastosowania różnego typu sztucznych sieci neuronowych do prognozowania sposobu przekazywania drgań od wstrząsów górniczych z gruntu na fundament budynku mieszkalnego o średniej wysokości.

Zdecydowano się na zastosowanie sieci z wektorami wejścia o różnej liczbie parametrów oraz o różnej kombinacji zastosowanych parametrów. W tabeli 4.1 zbiorczo przedstawiono wszystkie warianty analizowanych zestawień: wektor wejścia – wektor wyjścia.

Biorąc pod uwagę różne kombinacje parametrów wejściowych sieci, analizowano różne warianty wektorów wejścia. Rozważono 43 wersje kombinacji wektor wejścia – wektor wyjścia. Pod uwagę wzięto następujące parametry wejściowe sieci:  $a_{gmax}$  – maksymalną wartość (amplitudę) składowych przyspieszeń drgań gruntu w przypadku kierunku  $x$  lub  $y$ ,  $v_{gmax}$  – maksymalną wartość (amplitudę) składowych prędkości drgań gruntu w przypadku kierunku  $x$  lub  $y$ ,  $k$  – parametr opisujący kierunek drgań (w celu zróżnicowania kierunków, arbitralnie przyjęto  $k = 0.4$  i  $k = 0.7$  odpowiednio dla kierunku poprzecznego  $x$  oraz kierunku podłużnego  $y$ ),  $PGA$  – maksymalną wartość (amplitudę) wypadkowych przyspieszeń drgań gruntu,  $PGV$  – maksymalną wartość (amplitudę) wypadkowych prędkości drgań gruntu,  $X$  i  $Y$  – współrzędne sejsmologiczne w lokalnym układzie odniesienia,  $f_{ga}$  – dominujące częstotliwości przyspieszeń drgań gruntu oraz  $f_{gv}$  – dominujące częstotliwości prędkości drgań gruntu.

Na wyjściu z sieci oczekiwano  $r_{ax}$ ,  $r_{ay}$ ,  $r_{axy}$  w przypadku prognozowania przekazywania składowych przyspieszeń drgań odpowiednio w kierunku  $x$ , w kierunku  $y$ , oraz łącznie w kierunku  $x$  i  $y$ , ułamka  $r_{WA}$  do prognozowania przekazywania wypadkowych przyspieszeń drgań. W przypadku składowych prędkości drgań były to ułamki  $r_{vx}$ ,  $r_{vy}$ ,  $r_{vxy}$  odpowiednio w przypadku prognozowania przekazywania prędkości składowych w kierunku  $x$ , w kierunku  $y$  oraz łącznie w kierunku  $x$  i  $y$ . Natomiast w przypadku prognozowania przekazywania wypadkowych prędkości drgań z gruntu na fundament budynku oczekiwano ułamka  $r_{WV}$ .

Badano wpływ poszczególnych parametrów wejściowych sieci oraz wielkości informacji wejściowej na dokładność aproksymacji neuronowej.



Tabela 4.1

Analizowane warianty zestawień: wektor wejścia – wektor wyjścia

	Nr wariantu wektora wejścia	Wektor wejścia	Wektor wyjścia
składowe przyspieszenia drgań	1	$X_{axy(3x1)} = \{a_{gmax}, En, r_e\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	2	$X_{ax(3x1)} = \{a_{xgmax}, En, r_e\}$	$Y_{ax(1x1)} = \{r_{ax}\}$
	3	$X_{ay(3x1)} = \{a_{ygmmax}, En, r_e\}$	$Y_{ay(1x1)} = \{r_{ay}\}$
	4	$X_{axy(4x1)} = \{a_{gmax}, En, X, Y\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	5	$X_{ax(4x1)} = \{a_{xgmax}, En, X, Y\}$	$Y_{ax(1x1)} = \{r_{ax}\}$
	6	$X_{ay(4x1)} = \{a_{ygmmax}, En, X, Y\}$	$Y_{ay(1x1)} = \{r_{ay}\}$
	7	$X_{axy(4x1)} = \{a_{gmax}, En, r_e, f_{lga}\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	8	$X_{axy(4x1)} = \{a_{gmax}, En, r_e, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	9	$X_{axy(5x1)} = \{a_{gmax}, En, X, Y, f_{lga}\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	10	$X_{axy(5x1)} = \{a_{gmax}, En, X, Y, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	11	$X_{axy(5x1)} = \{a_{gmax}, En, r_e, f_{lga}, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	12	$X_{axy(5x1)} = \{a_{gmax}, En, r_e, X, Y\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	13	$X_{ax(5x1)} = \{a_{xgmax}, En, r_e, X, Y\}$	$Y_{ax(1x1)} = \{r_{ax}\}$
	14	$X_{ay(5x1)} = \{a_{ygmmax}, En, r_e, X, Y\}$	$Y_{ay(1x1)} = \{r_{ay}\}$
	15	$X_{axy(6x1)} = \{a_{gmax}, En, X, Y, f_{lga}, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	16	$X_{axy(6x1)} = \{a_{gmax}, En, r_e, X, Y, f_{lga}\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	17	$X_{axy(7x1)} = \{a_{gmax}, En, r_e, X, Y, f_{lga}, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
	18	$X_{axy(8x1)} = \{a_{gmax}, En, r_e, X, Y, f_{lga}, f_{2ga}, k\}$	$Y_{axy(1x1)} = \{r_{axy}\}$
przyspieszenia wypadkowe	19	$X_{wa(3x1)} = \{PGA, En, r_e\}$	$Y_{wa(1x1)} = \{r_{WA}\}$
	20	$X_{wa(4x1)} = \{PGA, En, X, Y\}$	$Y_{wa(1x1)} = \{r_{WA}\}$
	21	$X_{wa(5x1)} = \{PGA, En, r_e, X, Y\}$	$Y_{wa(1x1)} = \{r_{WA}\}$
składowe prędkości drgań	22	$X_{vxy(3x1)} = \{v_{gmax}, En, r_e\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	23	$X_{vx(3x1)} = \{v_{xgmax}, En, r_e\}$	$Y_{vx(1x1)} = \{r_{vx}\}$
	24	$X_{vy(3x1)} = \{v_{ygmmax}, En, r_e\}$	$Y_{vy(1x1)} = \{r_{vy}\}$
	25	$X_{vxy(4x1)} = \{v_{gmax}, En, X, Y\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	26	$X_{vx(4x1)} = \{v_{xgmax}, En, X, Y\}$	$Y_{vx(1x1)} = \{r_{vx}\}$
	27	$X_{vy(4x1)} = \{v_{ygmmax}, En, X, Y\}$	$Y_{vy(1x1)} = \{r_{vy}\}$
	28	$X_{vxy(4x1)} = \{v_{gmax}, En, r_e, f_{lgv}\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	29	$X_{vx(4x1)} = \{v_{xgmax}, En, r_e, f_{lgv}\}$	$Y_{vx(1x1)} = \{r_{vx}\}$
	30	$X_{vy(4x1)} = \{v_{ygmmax}, En, r_e, f_{lgv}\}$	$Y_{vy(1x1)} = \{r_{vy}\}$
	31	$X_{vxy(4x1)} = \{v_{gmax}, En, r_e, k\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	32	$X_{vxy(5x1)} = \{v_{gmax}, En, r_e, f_{lgv}, k\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	33	$X_{vxy(5x1)} = \{v_{gmax}, En, r_e, X, Y\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	34	$X_{vx(5x1)} = \{v_{xgmax}, En, r_e, X, Y\}$	$Y_{vx(1x1)} = \{r_{vx}\}$
	35	$X_{vy(5x1)} = \{v_{ygmmax}, En, r_e, X, Y\}$	$Y_{vy(1x1)} = \{r_{vy}\}$
	36	$X_{vxy(6x1)} = \{v_{gmax}, En, r_e, X, Y, k\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	37	$X_{vxy(6x1)} = \{v_{gmax}, En, r_e, X, Y, f_{lgv}\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	38	$X_{vx(6x1)} = \{v_{xgmax}, En, r_e, X, Y, f_{lgv}\}$	$Y_{vx(1x1)} = \{r_{vx}\}$
	39	$X_{vy(6x1)} = \{v_{ygmmax}, En, r_e, X, Y, f_{lgv}\}$	$Y_{vy(1x1)} = \{r_{vy}\}$
	40	$X_{vxy(7x1)} = \{v_{gmax}, En, r_e, X, Y, f_{lgv}, k\}$	$Y_{vxy(1x1)} = \{r_{vxy}\}$
	prędkości wypadkowe	41	$X_{wv(3x1)} = \{PGV, En, r_e\}$
42		$X_{wv(4x1)} = \{PGV, En, X, Y\}$	$Y_{wv(1x1)} = \{r_{WV}\}$
43		$X_{wv(5x1)} = \{PGV, En, r_e, X, Y\}$	$Y_{wv(1x1)} = \{r_{WV}\}$



gdzie:

$PGA$  – maksymalna wartość (amplituda) wypadkowej przyspieszeń drgań poziomych gruntu;

$PGV$  – maksymalna wartość (amplituda) wypadkowej prędkości drgań poziomych gruntu;

$a_{gmax}$  – maksymalna wartość (amplituda) przyspieszeń drgań poziomych gruntu w kierunku  $x$  i  $y$ ;

$a_{xgmax}$  – maksymalna wartość (amplituda) przyspieszeń drgań poziomych gruntu w kierunku  $x$ ;

$a_{ygmax}$  – maksymalna wartość (amplituda) przyspieszeń drgań poziomych gruntu w kierunku  $y$ ;

$v_{gmax}$  – maksymalna wartość (amplituda) prędkości drgań poziomych gruntu w kierunku  $x$  i  $y$ ;

$v_{xgmax}$  – maksymalna wartość (amplituda) prędkości drgań poziomych gruntu w kierunku  $x$ ;

$v_{ygmax}$  – maksymalna wartość (amplituda) prędkości drgań poziomych gruntu w kierunku  $y$ ;

$En$  – energia wstrząsu górniczego;

$r_e$  – odległość epicentralna;

$X, Y$  – współrzędne sejsmologiczne;

$k$  – parametr opisujący kierunek drgań:  $k = 0,4$  dla kierunku równoległego do osi poprzecznej budynku  $x$  oraz  $k = 0,7$  dla kierunku równoległego do osi podłużnej budynku  $y$ ;

$f_{1ga}$  – pierwsza dominująca częstotliwość przyspieszeń drgań gruntu;

$f_{2ga}$  – druga dominująca częstotliwość przyspieszeń drgań gruntu;


$f_{1gv}$  – pierwsza dominująca częstotliwość prędkości drgań gruntu.

Wykorzystując dane doświadczalne, w przypadku przyspieszeń oraz prędkości drgań składowych do analizy neuronowej wzięto po  $P = 464$  wzorców dla każdego z wariantów par wektor wejścia – wektor wyjścia. W przypadku każdego z wariantów: wektor wejścia – wektor wyjścia w sposób losowy podzielono wzorce wykorzystane w danych sieciach na trzy zbiory w proporcjach: 50% wszystkich wzorców stanowiło zbiór uczący, 25% – zbiór walidujący oraz 25% – zbiór testujący. Analogiczny podział wzorców zaproponowano w przypadku przyspieszeń oraz prędkości drgań wypadkowych:  $P = 226$ ,  $L = 113$ ,  $V = 56$ ,  $T = 57$ .


Obliczenia wykonano za pomocą standardowych sztucznych sieci neuronowych (SSN) typu wstecznej propagacji błędu (WPB) z algorytmem uczenia Levenberga – Marquardta (LM) [5, 98], sztucznych sieci neuronowych z regularyzacją (SSN+reg.) [5], bayesowskich sieci neuronowych (BSN) [20, 87]. Zaproponowano też użycie kaskadowych sieci neuronowych (KSN) [89, 90]. Zastosowano sigmoidalną unipolarną (logistyczną) funkcję aktywacji. Do obliczeń wykorzystano program Matlab NN Toolbox [98].

Przeprowadzono szereg obliczeń, w celu zaprojektowania optymalnej sieci do prognozowania przekazywana składowych oraz wypadkowych przyspieszeń drgań z gruntu na fundament budynku, jak również sieci do prognozowania przekazywana składowych oraz wypadkowych prędkości drgań z gruntu na fundament budynku we wszystkich wariantach wektor wejścia – wektor wyjścia. Kryterium doboru struktury sieci neuronowej był możliwie najmniejszy błąd  $MSE$  dla uczenia i walidacji. Rozważano sieci z jedną warstwą ukrytą. Poszukiwano optymalnej sieci w zależności od liczby neuronów w warstwie ukrytej oraz liczby epok uczenia sieci. W przypadku sieci neuronowej z regularyzacją, dodatkowym parametrem wpływającym na dobór optymalnej architektury sieci była wartość współczynnika regularyzacji  $\gamma$ .

Przykładowo na rys. 4.1 przedstawiono zależność błędów  $MSE$  od liczby neuronów w warstwie ukrytej przy 60 epokach uczenia w przypadku standardowej sztucznej sieci neuronowej z wektorem wejścia nr 22 (SSN 22) –  $x_{vxy(3 \times 1)} = \{v_{gmax}, En, r_e\}$ , do prognozowania przekazywania składowych prędkości drgań łącznie w kierunku  $x$  i  $y$ . Natomiast na rys. 4.2 pokazano wyniki analizy wielkości błędu  $MSE$  w zależności od liczby epok uczenia przy 8 neuronach w warstwie ukrytej SSN 23 do wyznaczenia ułamka  $r_{vx}$ . Wektor wejścia SSN 23 został zbudowany z następujących parametrów  $x_{vx(3 \times 1)} = \{v_{xgmax}, En, r_e\}$  (por. tabela 4.1).




Rys. 4.1. Zależność błędu  $MSE$  od liczby neuronów w warstwie ukrytej dla SSN 22




Rys. 4.2 Zależność błędu  $MSE$  od liczby epok uczenia przy 8 neuronach w warstwie ukrytej dla SSN 23

Analogiczne badania przeprowadzono przykładowo w przypadku doboru architektury sieci SSN 19 ( $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$ ) do prognozowania przekazywania wypadkowych przyspieszeń drgań. Rys. 4.3 przedstawia wykres zależności błędów  $MSE$  od liczby neuronów w warstwie ukrytej przy 40 epokach uczenia. Natomiast na rys. 4.4 pokazano zmiany błędów  $MSE$  w zależności od liczby epok uczenia dla sieci o 3 neuronach w warstwie ukrytej.




Rys. 4.3 Zależność błędu  $MSE$  od liczby neuronów w warstwie ukrytej dla SSN 19 (40 epok uczenia)



Rys. 4.4 Zależność błędu  $MSE$  od liczby epok uczenia dla sieci o 3 neuronach w warstwie ukrytej sieci neuronowej SSN 19

Rys. 4.5 przykładowo ilustruje zmiany błędu  $MSE$  w zależności od wartości współczynnika regularyzacji  $\gamma$  w przypadku sieci SSN+reg. o architekturze 3 – 40 – 1, uczonej przez 10 epok z błędami  $MSE(L) = 0,0210$   $MSE(V) = 0,0256$   $MSE(T) = 0,0275$ . Takie błędy pojawiają się w przypadku sieci z wektorem wejścia  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$  do prognozowania ułamka  $r_{WA}$ . Widać, że dobór wartości współczynnika  $\gamma$  może mieć istotny wpływ na otrzymane błędy  $MSE$  uczenia, walidacji oraz testowania sieci z regularyzacją. Przykładowo dla analizowanej sieci, w przypadku prognozowania ułamka  $r_{WA}$  zdecydowano się na sieć ze współczynnikiem  $\gamma = 0,05$ , co spowodowało równoczesne uzyskanie małych błędów  $MSE$  uczenia, walidacji oraz testowania.



Rys. 4.5. Zależność błędu  $MSE$  od współczynnika regularyzacji  $\gamma$  w przypadku sieci o wektorze wejścia  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$ , architekturze 3-40-1 i 10 epokach uczenia

## 4.2. Wyniki obliczeń z użyciem standardowych sztucznych sieci neuronowych typu WPB

### 4.2.1. Analiza przekazywania składowych przyspieszeń drgań


Wyboru optymalnych sieci z najmniejszymi błędami  $MSE$  dla uczenia, walidacji oraz testowania dokonano w wyniku wielu analiz. W tabeli 4.2 zamieszczono informacje dotyczące architektury sieci oraz liczby wzorców uczących ( $L$ ), walidujących ( $V$ ) i testujących ( $T$ ), a także podano liczbę epok uczenia i błędy  $MSE$ . Są to sieci do prognozowania przekazywania składowych przyspieszeń drgań w kierunku  $x$ , w kierunku  $y$  oraz łącznie w kierunku  $x$  i  $y$ . Numeracja sieci jest zgodna z zestawieniem przedstawionym w tabeli 4.1, gdzie zawarto informację o uwzględnionych parametrach wektora wejścia oraz wyjścia.

Tabela 4.2


Liczba wzorców, architektura i błędy  $MSE$  zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania składowych przyspieszeń drgań

Nr wariantu wektora wejścia	Liczba wzorców			Architektura sieci	Liczba epok uczenia	$MSE$		
	$L$	$V$	$T$			$L$	$V$	$T$
1	232	116	116	3-25-1	20	0,0194	0,0237	0,0220
2	115	57	58	3-8-1	40	0,0159	0,0121	0,0130
3	116	59	59	3-4-1	60	0,0138	0,0161	0,0186
4	232	116	116	4-5-1	40	0,0212	0,0232	0,0236
5	115	57	58	4-6-1	50	0,0112	0,0114	0,0119
6	116	59	59	4-16-1	20	0,0156	0,0242	0,0198
7	232	116	116	4-22-1	50	0,0153	0,0157	0,0166
8	232	116	116	4-7-1	45	0,0150	0,0148	0,0143
9	232	116	116	5-4-1	50	0,0167	0,0175	0,0175
10	232	116	116	5-10-1	50	0,0137	0,0148	0,0140
11	232	116	116	5-15-1	30	0,0095	0,0115	0,0114
12	232	116	116	5-7-1	30	0,0229	0,0250	0,0228
13	115	57	58	5-14-1	40	0,0139	0,0140	0,0127
14	116	59	59	5-7-1	10	0,0121	0,0168	0,0160
15	232	116	116	6-15-1	50	0,0079	0,0095	0,0104
16	232	116	116	6-5-1	50	0,0184	0,0174	0,0184
17	232	116	116	7-4-1	50	0,0129	0,0120	0,0103
18	232	116	116	8-23-1	10	0,0128	0,0123	0,0111

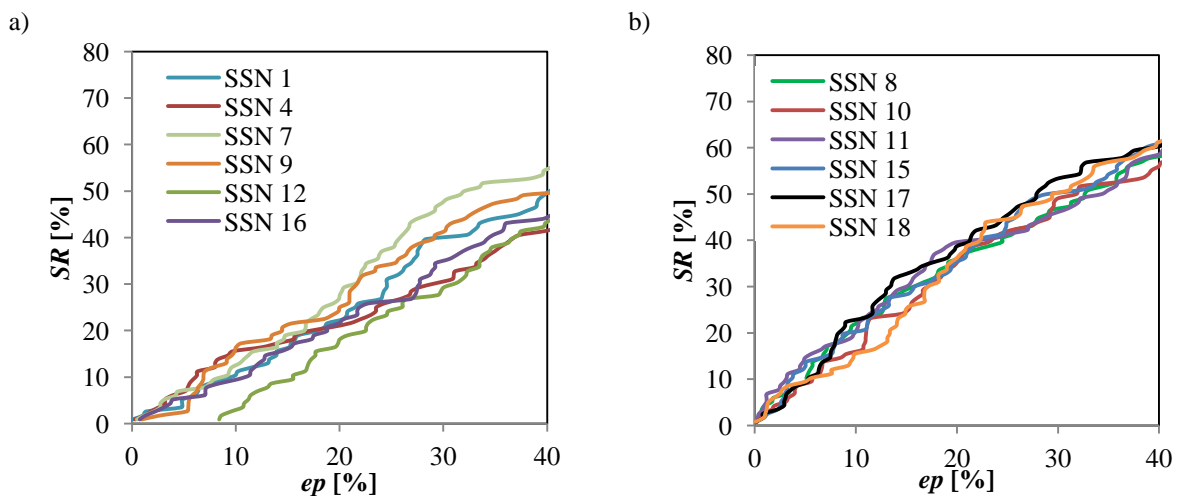
Na rys. 4.6, rys. 4.7, rys. 4.8 odpowiednio przedstawiono procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku uczenia, walidacji oraz testowania w przypadku prognozowania ułamka  $r_{axy}$ . Zastosowano sieci z parametrem kierunkowym  $k$  w wektorze wejścia (a) oraz bez parametru  $k$  w wektorze wejściowym (b).



Rys. 4.6. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań składowych z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze uczącym:  
a) bez parametru  $k$ , b) z parametrem  $k$

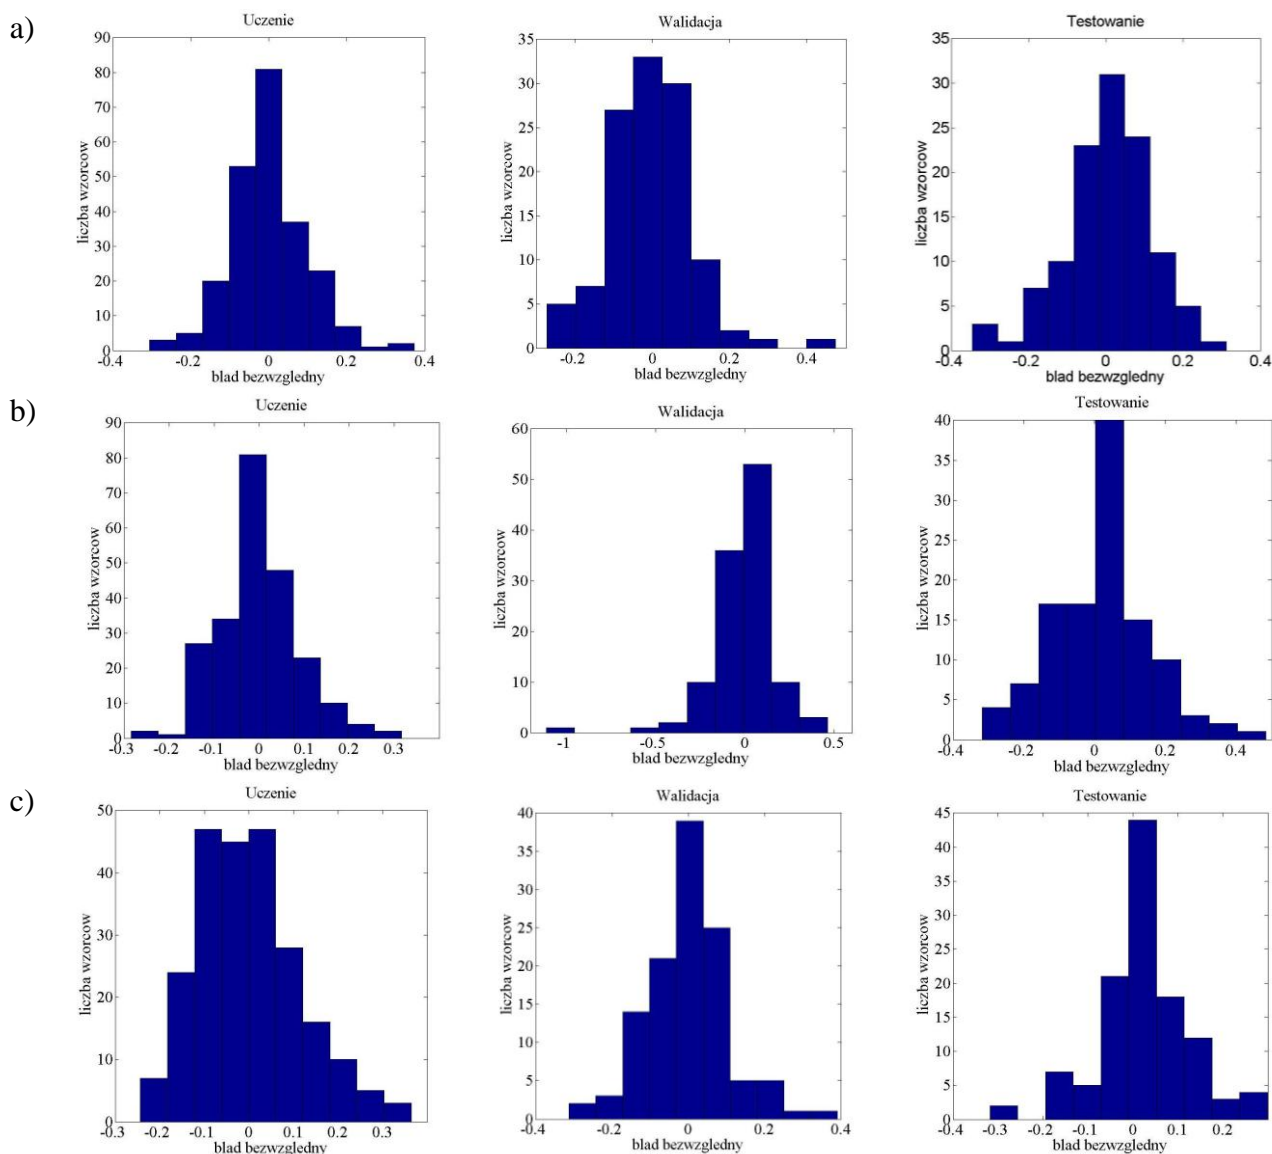


Rys 4.7. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze walidującym:  
a) bez parametru  $k$ , b) z parametrem  $k$



Rys. 4.8. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze testującym:  
a) bez parametru  $k$ , b) z parametrem  $k$


Dodatkowo na rys. 4.9 przedstawiono histogramy błędu bezwzględnego  $E_p$  wyznaczone w przypadku sieci SSN 11 (a), SSN 15 (b), SSN 17 (c).




Rys. 4.9. Histogramy błędu bezwzględnego  $E_p$ : a) SSN 11 b) SSN 15, c) SSN 17

Na rys. 4.10 przedstawiono wartość ułamka  $r_{axy}$  wyznaczoną na podstawie pomiarów i obliczoną za pomocą sieci SSN 11 (a), SSN 15 (b), SSN 17 (c).


a)



b)



c)



Rys. 4.10. Wartość ułamka  $r_{axy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą:  
a) SSN 11, b) SSN 15, c) SSN 17



Biorąc pod uwagę najmniejsze błędy  $MSE$  uczenia, walidacji i testowania oraz największy procent sukcesu  $SR$  zauważono, że w prognozowaniu wartości ułamka  $r_{axy}$  najlepsze wyniki uzyskano w przypadku zastosowania SSN 11, SSN 15 oraz SSN 17. Wektory wejścia sieci SSN 11, SSN 15, oraz SSN 17 odpowiednio zostały zbudowane z następujących parametrów:  $x_{axy(5x1)} = \{a_{gmax}, En, r_e, f_{lga}, k\}$ ,  $x_{axy(6x1)} = \{a_{gmax}, En, X, Y, f_{lga}, k\}$ ,  $x_{axy(7x1)} = \{a_{gmax}, En, r_e, X, Y, f_{lga}, k\}$ . Widać, że dołożenie w wektorze wejścia sieci parametru  $k$  opisującego kierunek drgań, ewentualnie  $f_{lga}$  – dominującej częstotliwości przyspieszeń drgań gruntu wyraźnie zwiększa dokładność obliczeń.

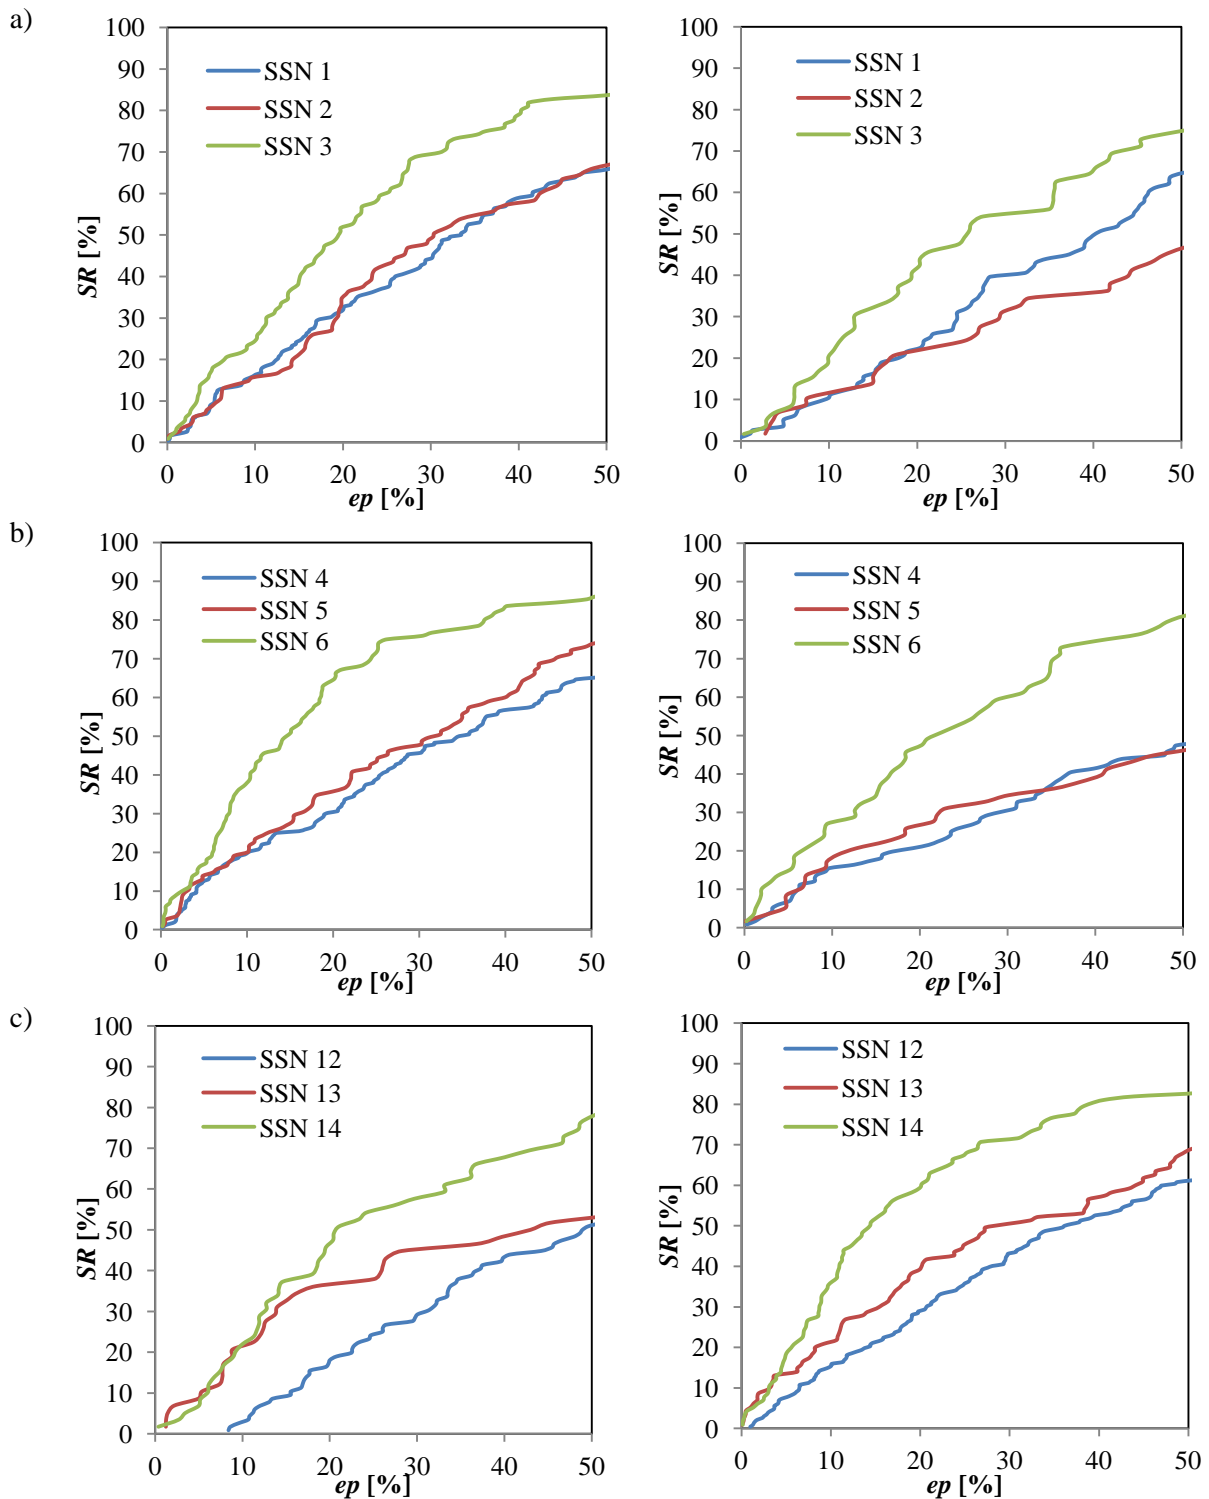
Analizując standardowe sieci neuronowe do prognozowania ułamka  $r_{axy}$ , w których w wektorze wejścia nie uwzględniono parametru  $k$  opisującego kierunek drgań, największy procent sukcesu  $SR$  uzyskano w przypadku testowania SSN 7 oraz SSN 9 (rys. 4.8 a). Są to sieci o wektorach wejściowych: SSN 7 –  $x_{axy(4x1)} = \{a_{gmax}, En, r_e, f_{lga}\}$ , SSN 9 –  $x_{axy(5x1)} = \{a_{gmax}, En, X, Y, f_{lga}\}$ . Biorąc pod uwagę sieci neuronowe z wektorami wejścia bez uwzględnienia parametru kierunkowego  $k$ , zauważono również, iż największy procent sukcesu  $SR$  uzyskano w przypadku sieci, gdzie uwzględniono w obliczeniach dominujące częstotliwości przyspieszeń drgań na gruncie. Jeżeli w analizowanych sieciach nie uwzględniono dominujących częstotliwości przyspieszeń drgań gruntu uzyskano procent sukcesu  $SR$  o około 10 % mniejszy dla  $ep = 10 - 40\%$ .

Analizując dokładności wyników obliczeń z użyciem sieci do prognozowania przekazywania składowych przyspieszeń drgań stwierdzono, iż najmniejszy procent sukcesu  $SR$  uzyskano w przypadku SSN 4 ( $x_{ay(4x1)} = \{a_{ygmax}, En, X, Y\}$ ) oraz SSN 12 ( $x_{ay(5x1)} = \{a_{ygmax}, En, r_e, X, Y\}$ ). Jest to spowodowane brakiem w wektorze wejścia parametru kierunkowego  $k$  oraz informacji o wartościach dominujących częstotliwości przyspieszeń drgań gruntu. Przykładowo w zbiorze uczącym otrzymano:  $SR(30\%) = 66\%$  w przypadku SSN 11,  $SR(30\%) = 65\%$  w przypadku SSN 15,  $SR(30\%) = 56\%$  w przypadku SSN 17, a  $SR(30\%) = 45\%$ ,  $SR(30\%) = 43\%$  odpowiednio w przypadku SSN 4 oraz SSN 12. Podanie w wektorze wejścia sieci zarówno informacji o dominującej częstotliwości przyspieszeń drgań gruntu jak i o kierunku drgań (SSN 11), pozwala na zwiększenie wartości  $SR$  nawet o ponad 20 % (por. rys. 4.7 b).

Podając w wektorze wejścia informację o wzajemnym położeniu budynku i epicentrum wstrząsu górniczego, a więc wprowadzając współrzędne sejsmologiczne ( $X, Y$ ) zamiast odległości epicentralnej  $r_e$ , można znacząco zwiększyć procent sukcesu  $SR$ . Do takich wniosków prowadzi analiza rezultatów uzyskanych w przypadku przyspieszeń drgań składowych: łącznie w kierunku  $x$  i  $y$  (np. SSN 1, SSN 4 i SSN 12; SSN 7 i SSN 9), osobno w kierunku  $x$ , (SSN 2, SSN 5 i SSN 13), osobno w kierunku  $y$  (SSN 3, SSN 6 i SSN 14).

Na rys. 4.11 a, b, c porównano procent sukcesu  $SR$  sieci neuronowych do prognozowania ułamka  $r_a$  w przypadku kierunku  $x$ , kierunku  $y$  oraz równocześnie kierunku  $x$  i  $y$  dla SSN 1, SSN 2, SSN 3 o wektorze wejścia  $x_{(3x1)} = \{a_{gmax}, En, r_e\}$ ; SSN 4, SSN 5, SSN 6 o wektorze

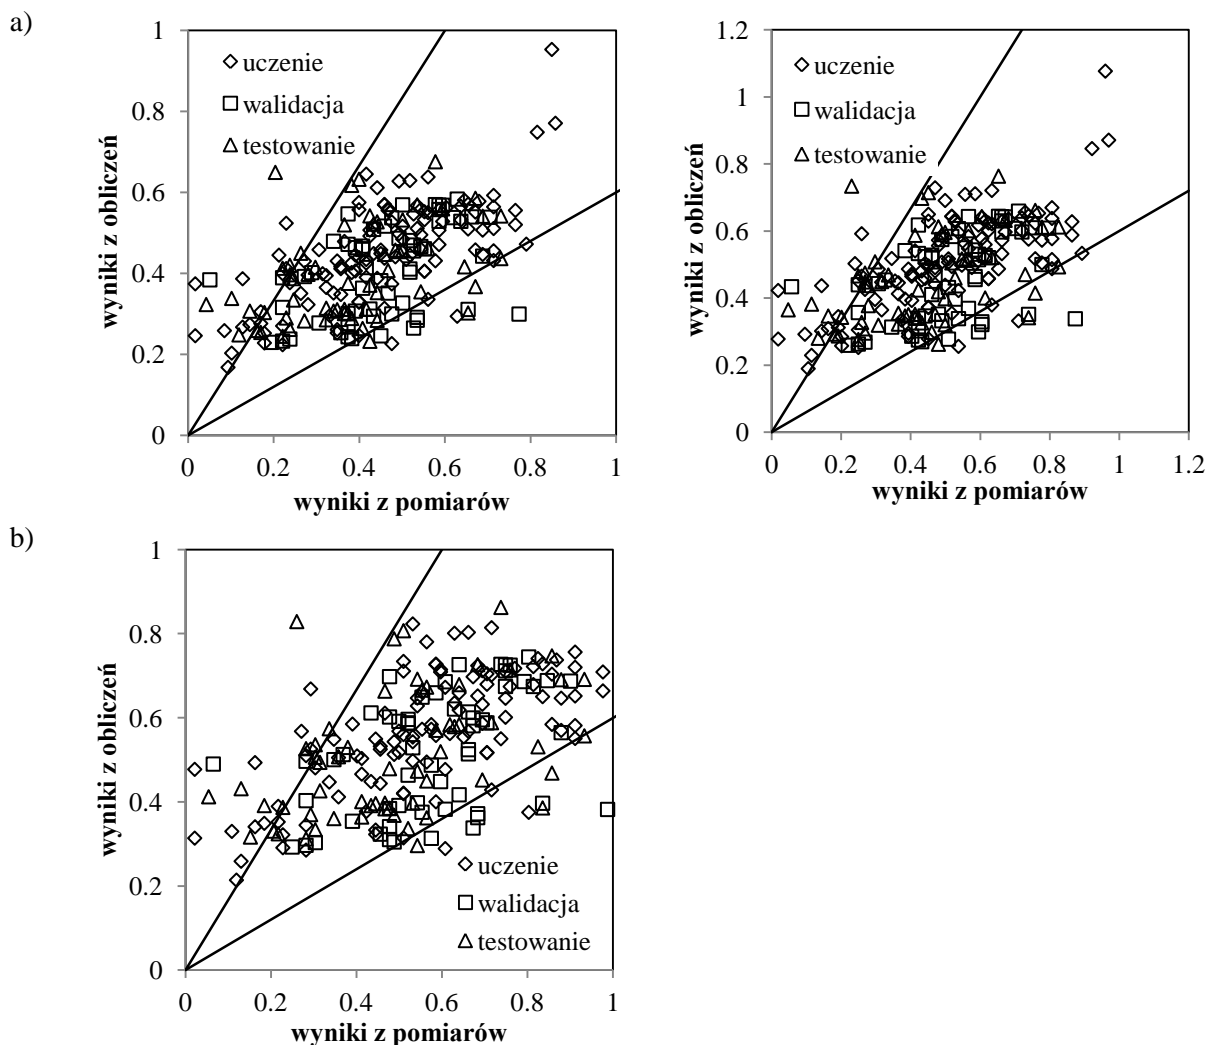
wejścia  $x_{(4 \times 1)} = \{a_{gmax}, En, X, Y\}$  oraz SSN 12, SSN 13, SSN 14 o wektorze wejścia  $x_{(5 \times 1)} = \{a_{gmax}, En, r_e, X, Y\}$ .



Rys. 4.11. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek – uczenie, testowanie – w przypadku sieci do prognozowania ułamka  $r_a$  z wektorem wejścia:  
a)  $x_{a(3 \times 1)} = \{a_{gmax}, En, r_e\}$ , b)  $x_{a(4 \times 1)} = \{a_{gmax}, En, X, Y\}$ , c)  $x_{a(5 \times 1)} = \{a_{gmax}, En, r_e, X, Y\}$

Z przeprowadzonej analizy wynika, że najlepsze rezultaty neuronowego przewidywania ułamka  $r_a$  uzyskano w przypadku kierunku podłużnego  $y$  (najmniejsze błędy  $MSE$  uczenia, walidacji oraz testowania oraz największy procent sukcesu  $SR$ ). Kierunek podłużny  $y$  jest zatem stosunkowo dobrze „przewidywalny”. Takie wyniki uzyskano dla wszystkich analizowanych sieci do prognozowania przekazywania składowych przyspieszeń drgań, niezależnie od wariantu wektora wejścia. W przypadku kierunku podłużnego  $y$  wartości  $SR$  mogą być nawet o ponad 30% większe w pewnych zakresach błędu  $ep$  (por. np. rys. 4.11b). Największe błędy przy wyliczaniu ułamka  $r_a$ , za pomocą techniki neuronowej pojawiają się przy próbie „łączonego” uwzględnienia obu kierunków drgań (SSN 1, SSN 4, nr 12), co jest wynikiem znacznych różnic w sposobie przekazywania drgań w kierunkach:  $x$  i  $y$  (a tym samym we wzorcach im odpowiadającym).

Na rys. 4.12 a, b, c porównano wartości ułamka  $r_{ay}$  wyliczone na podstawie pomiarów i za pomocą sieci neuronowych odpowiednio SSN 3, SSN 6, SSN 14 do wykorzystania odrębnie w przypadku kierunku  $y$ . Zaznaczono granicę błędu względnego  $ep = 40\%$ .



Rys. 4.12. Wartość ułamka  $r_{ay}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 3, b) SSN 6, c) SSN 14

#### 4.2.2. Analiza przekazywania wypadkowych przyspieszeń drgań

Wyboru optymalnych sieci z najmniejszymi błędami *MSE* uczenia, walidacji oraz testowania dokonano w wyniku wielu analiz. W tabeli 4.3 zamieszczono informacje dotyczące architektury sieci oraz liczby wzorców uczących (*L*), walidujących (*V*) i testujących (*T*), a także podano liczbę epok uczenia i błędy *MSE*. Są to sieci do prognozowania przekazywania wypadkowych przyspieszeń drgań. Numeracja sieci jest zgodna z zestawieniem przedstawionym w tabeli 4.1, gdzie zawarto informację o uwzględnionych parametrach wektora wejścia oraz wyjścia.

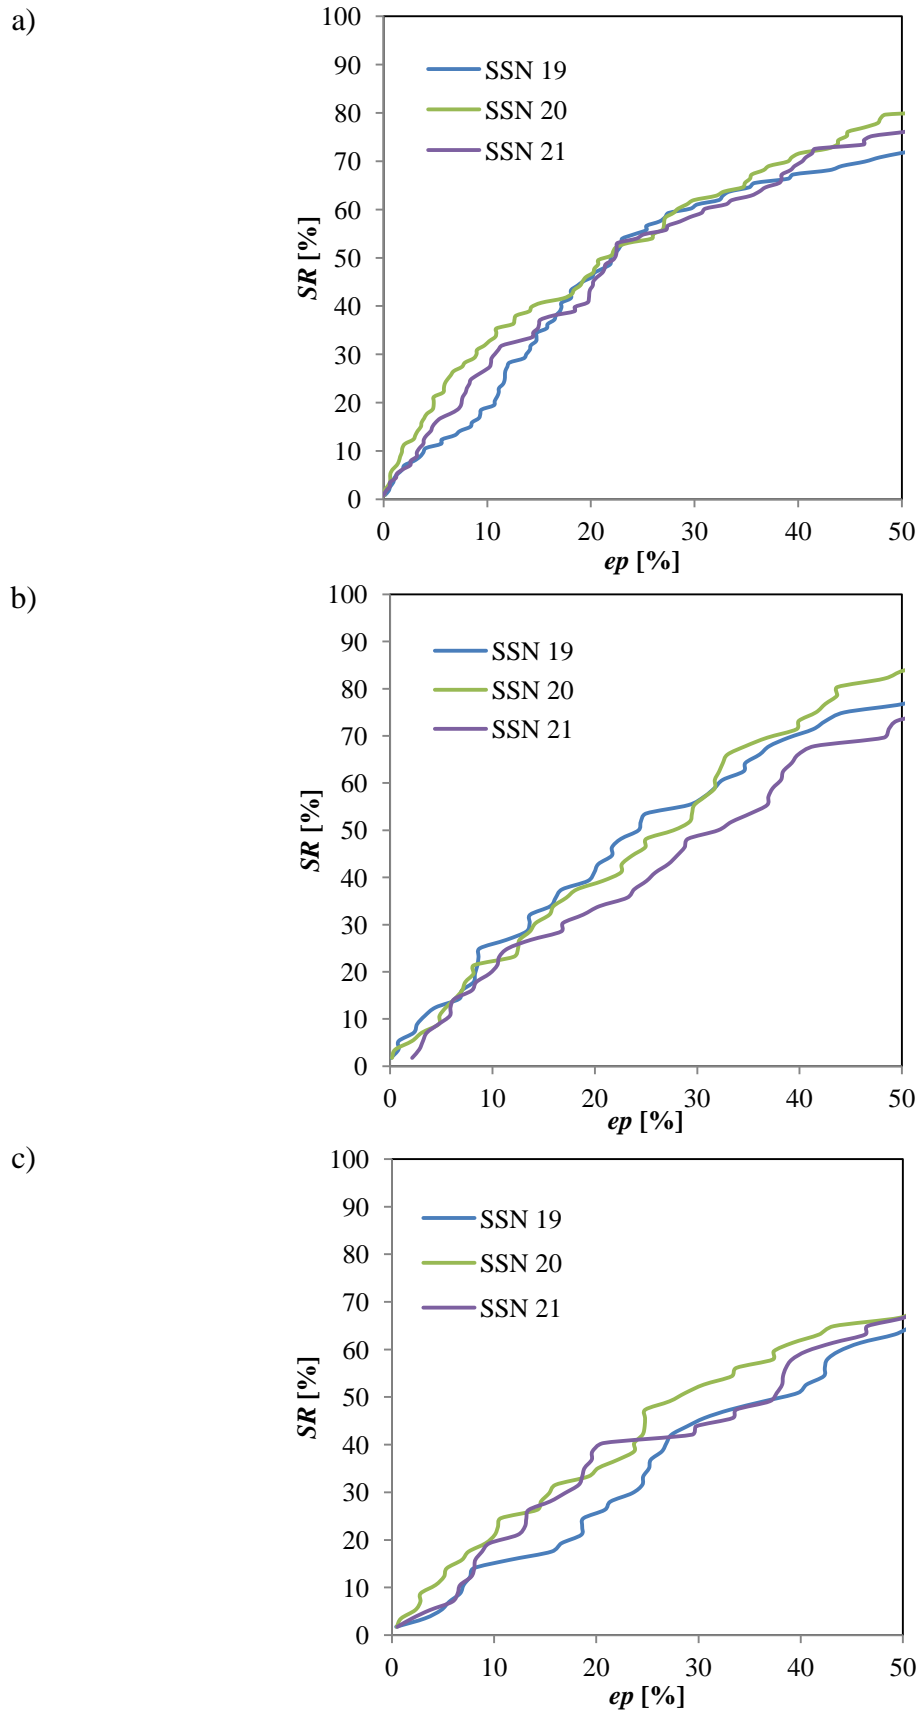
Tabela 4.3

Liczba wzorców, architektura i błędy *MSE* zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania wypadkowych przyspieszeń drgań


Nr wariantu wektora wejścia	Liczba wzorców			Architektura sieci	Liczba epok uczenia	<i>MSE</i>		
	<i>L</i>	<i>V</i>	<i>T</i>			<i>L</i>	<i>V</i>	<i>T</i>
19	113	56	57	3-3-1	40	0,0222	0,0241	0,0266
20	113	56	57	4-22-1	20	0,0182	0,0180	0,0190
21	113	56	57	5-6-1	55	0,0208	0,0275	0,0192

Analizowano sieci z różną kombinacją parametrów wejściowych: maksymalne wypadkowe przyspieszenie drgań gruntu, odległość epicentralna, energia wstrząsów górniczych oraz współrzędne sejsmologiczne *X* i *Y*. Do prognozowania ułamka  $r_{WA}$  zaproponowano więc SSN 19, SSN 20 oraz SSN 21 odpowiednio z wektorami wejścia:  $x_{wa(3x1)} = \{PGA, En, r_e\}$ ,  $x_{wa(4x1)} = \{PGA, En, X, Y\}$ ,  $x_{wa(5x1)} = \{PGA, En, r_e, X, Y\}$ .

Na rys. 4.13 przedstawiono procent sukcesu *SR* neuronowej prognozy przekazywania wypadkowych przyspieszeń drgań z gruntu na budynek w przypadku uczenia (a), walidacji (b) oraz testowania (c) sieci SSN 19, SSN 20, SSN 21. Natomiast rys. 4.14 przedstawia histogramy błędów bezwzględnych *Ep* uczenia (a), walidacji (b) oraz testowania (c) sieci SSN 19.



Rys. 4.13. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku sieci SSN 19, SSN 20, SSN 21 : a) uczenie, b) walidacja, b) testowanie




Rys. 4.14. Histogramy błędu bezwzględnego  $Ep$  SSN 19: a) uczenie, b) walidacja, c) testowanie

Stwierdzono, że największy procent sukcesu  $SR$  uzyskano z użyciem SSN 20. Zauważono, iż podanie w informacji wejściowej sieci neuronowej współrzędnych sejsmologicznych ( $X$ ,  $Y$ ) wstrząsu górniczego zamiast odległości epicentralnej  $r_e$  (SSN 19), może istotnie wpłynąć na zwiększenie dokładności neuronowej prognozy przekazywania przyspieszeń drgań wypadkowych z gruntu na fundament budynku. Szczególnie duże zwiększenie procentu sukcesu  $SR$  obserwuje się w zbiorze testującym (por. rys. 4.13c). Różnice w wartościach  $SR$  obliczonych dla kolejnych błędów  $ep$  sięgają nawet kilkunastu procent. Uwzględnienie w wektorze wejścia zarówno odległości epicentralnych, jak


i współrzędnych sejsmologicznych nie zmienia znacząco uzyskanych rezultatów (por. SSN 20 i SSN 21).

Rys. 4.15 porównuje wartości ułamka  $r_{WA}$  wyliczone na podstawie pomiarów i obliczone za pomocą tej SSN 19 (a), SSN 20 (b) oraz SSN 21(c). Zaznaczono granicę błędu względnego  $ep=40\%$ .


a)



b)



c)



Rys. 4.15. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczona za pomocą:  
a) SSN 19, b) SSN 20, c) SSN 21

### 4.2.3. Analiza przekazywania składowych prędkości drgań

Wyboru optymalnych sieci z najmniejszymi błędami *MSE* uczenia, walidacji oraz testowania dokonano w wyniku wielu analiz. W tabeli 4.4 zamieszczono informacje dotyczące architektury sieci oraz liczby wzorców uczących (*L*), walidujących (*V*) i testujących (*T*), a także podano liczbę epok uczenia i błędy *MSE*. Są to sieci do prognozowania przekazywania składowych prędkości drgań w kierunku *x*, w kierunku *y* oraz łącznie w kierunku *x* i *y*. Numeracja sieci jest zgodna z zestawieniem przedstawionym w tabeli 4.1, gdzie zawarto informację o uwzględnionych parametrach wektora wejścia oraz wyjścia.


Tabela 4.4

Liczba wzorców, architektura i błędy *MSE* zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania składowych prędkości drgań


Nr wariantu wektora wejścia	Liczba wzorców			Architektura sieci	Liczba epok uczenia	<i>MSE</i>		
	<i>L</i>	<i>V</i>	<i>T</i>			<i>L</i>	<i>V</i>	<i>T</i>
22	232	116	116	3-5-1	60	0,0092	0,0107	0,0097
23	115	57	58	3-8-1	80	0,0098	0,0074	0,0089
24	117	58	59	3-4-1	150	0,0053	0,0047	0,0047
25	232	116	116	4-3-1	10	0,0124	0,0127	0,0112
26	115	57	58	4-5-1	25	0,0132	0,0113	0,0121
27	117	58	59	4-6-1	20	0,0096	0,0049	0,0051
28	232	116	116	4-24-1	40	0,0110	0,0122	0,0118
29	115	57	58	4-5-1	40	0,0061	0,0082	0,0064
30	117	58	59	4-7-1	20	0,0063	0,0058	0,0053
31	232	116	116	4-18-1	40	0,0073	0,0072	0,0072
32	232	116	116	5-8-1	50	0,0059	0,0066	0,0057
33	232	116	116	5-12-1	10	0,0129	0,0131	0,0113
34	115	57	58	5-11-1	10	0,0145	0,0095	0,0079
35	117	58	59	5-6-1	60	0,0049	0,0050	0,0047
36	232	116	116	6-11-1	40	0,0079	0,0072	0,0055
37	232	116	116	6-12-1	40	0,0095	0,0119	0,0112
38	115	57	58	6-6-1	20	0,0078	0,0084	0,0069
39	117	58	59	6-7-1	20	0,0046	0,0047	0,0049
40	232	116	116	7-17-1	10	0,0089	0,0058	0,0053




W przypadku przekazywania składowych prędkości drgań łącznie w kierunku  $x$  i  $y$  zdecydowano się na analizę 8 sieci o różnych kombinacjach parametrów w wektorach wejścia. Na rys. 4.16, rys. 4.17, rys. 4.18 przedstawiono procent sukcesu  $SR$  prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku uczenia, walidacji oraz testowania sieci do prognozowania ułamka  $r_{vxy}$ : bez parametru  $k$  opisującego kierunek drgań oraz z parametrem  $k$  w wektorach wejścia.



Rys. 4.16. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku uczenia: a) bez parametru  $k$ , b) z parametrem  $k$

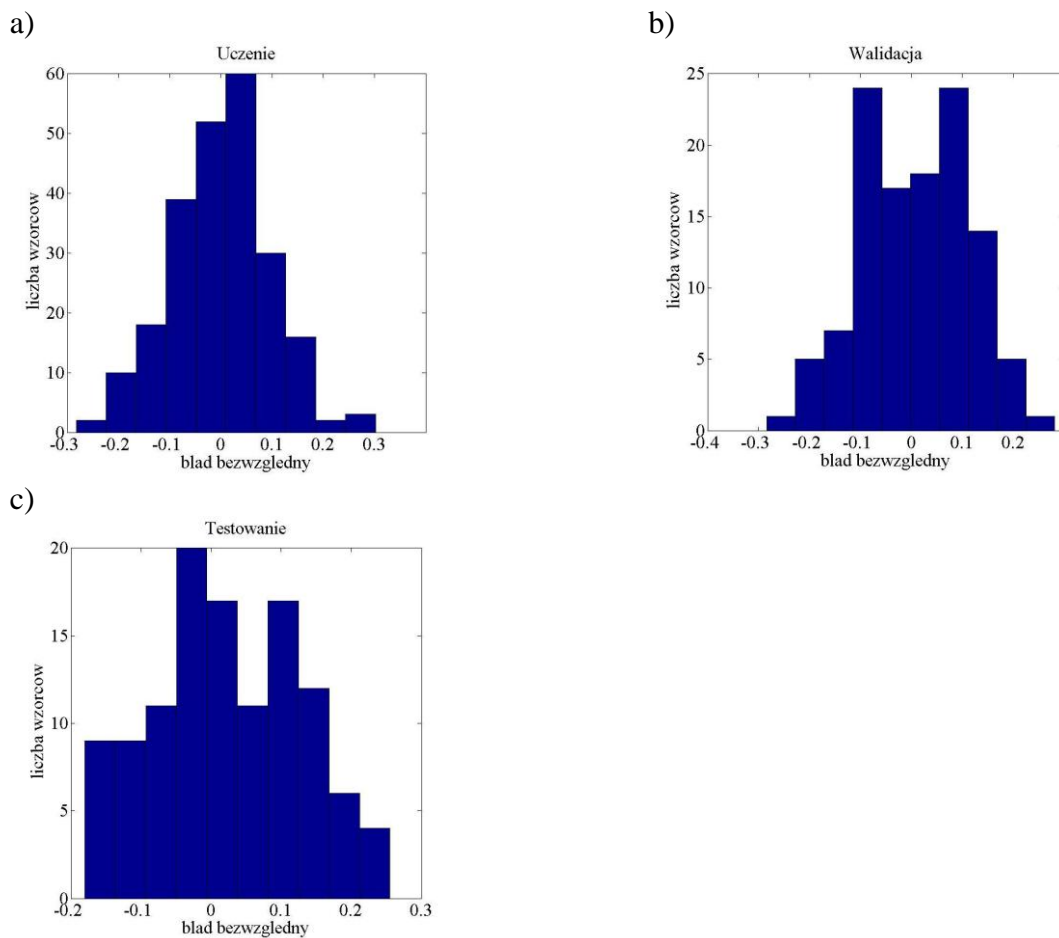


Rys. 4.17. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku walidacji: a) bez parametru  $k$ , b) z parametrem  $k$



Rys. 4.18. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku testowania: a) bez parametru  $k$ , b) z parametrem  $k$

Przykładowo rys. 4.19 przedstawia histogramy błędów bezwzględnych  $Ep$  uczenia (a), walidacji (b) i testowania (c) SSN 37 (do łącznego wykorzystania w kierunku  $x$  i  $y$ ).



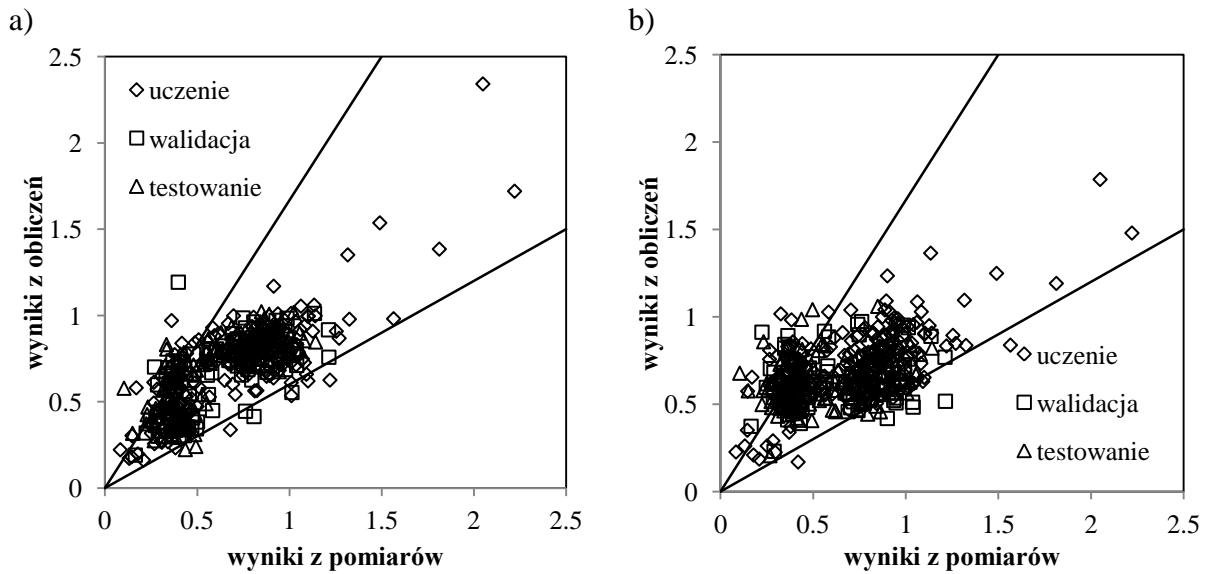
Rys. 4.19. Histogramy błędu bezwzględnego  $Ep$  SSN 37: a) uczenie, b) walidacja, c) testowanie

Z analizy wszystkich uzyskanych rezultatów wynika, że z przy prognozowaniu wartości ułamka  $r_{vxy}$  najlepsze przybliżenia uzyskano, podobnie jak było to w przypadku przyspieszeń drgań, z zastosowaniem sieci zawierających w wektorach wejścia parametr  $k$  opisujący kierunek drgań. W przypadku tych sieci uzyskano najmniejsze błędy  $MSE$  uczenia, walidacji i testowania. Dzięki rozbudowaniu wektorów wejściowych sieci o parametr decydujący o dostarczeniu informacji opisującej kierunek drgań uzyskano procentu sukcesu większy o około 10 % przy błędzie  $ep = 30 - 50\%$ , w stosunku do sieci, które zostały zamodelowane bez parametru  $k$  w wektorze wejścia.

Biorąc pod uwagę tylko sieci bez parametru  $k$  w wektorze wejścia, najlepsze wyniki uzyskano w przypadku SSN 37. SSN 37 ma następujące parametry w wektorze wejścia:  $x_{vxy(6x1)} = \{v_{gmax}, En, r_e, X, Y, f_{Igv}\}$ . Stwierdzono, że dodanie do wektora wejściowego informacji dotyczącej dominujących częstotliwości prędkości drgań gruntu, umożliwia uzyskanie lepszych wyników, niż w przypadku, gdy ten parametr został pominięty (por. np. rys. 4.18 a, b, c). Spostrzeżenia te ilustrują też wyniki prognozowania ułamka  $r_{vxy}$  za pomocą SSN 28 ( $x_{vxy(4x1)} = \{v_{gmax}, En, r_e, f_{Igv}\}$ ).


W przypadku sieci neuronowych do prognozowania przekazywania składowych prędkości drgań z gruntu na fundament budynku, w których w wektorze wejściowym został zdefiniowany parametr kierunkowy  $k$ , najlepsze wyniki uzyskano z zastosowaniem SSN 40. Wektor wejściowy SSN 40 jest zbudowany z następujących parametrów  $x_{vxy(7x1)} = \{v_{gmax}, En, r_e, X, Y, f_{Igv}, k\}$ . Dla SSN 40 uzyskano najmniejsze błędy  $MSE$  uczenia, walidacji oraz testowania. W przypadku tej sieci uzyskano również największy procent sukcesu  $SR$ . Zauważono, iż analogicznie jak w przypadkach różnych wariantów wektorów wejścia bez parametru  $k$ , na poprawę wyników wpływa dodanie dominujących częstotliwości prędkości drgań gruntu oraz zamiana parametru jakim jest odległość epicentralna  $r_e$  na współrzędne sejsmologiczne  $X, Y$ . (większy procent sukcesu  $SR$  o ok. 10% w przypadku błędu  $ep = 30 - 50\%$ ).

Rys. 4.20 porównuje wartości ułamka  $r_{vxy}$  wyliczone na podstawie pomiarów i obliczone za pomocą tej SSN 32 (a) z wektorem wejścia  $x_{vxy(5x1)} = \{v_{gmax}, En, r_e, f_{gl}, k\}$  oraz SSN 37 (b) z wektorem wejścia  $x_{vxy(6x1)} = \{v_{gmax}, En, r_e, X, Y, f_{gl}\}$ . Zaznaczono granicę błędu względnego  $ep=40\%$ .




Rys. 4.20. Wartość ułamka  $r_{vy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą:  
a) SSN 32, b) SSN 37


Oprócz analizy możliwości neuronowego prognozowania przekazywania składowych prędkości drgań łącznie w kierunku  $x$  i  $y$ , podjęto próbę zaprojektowania sieci neuronowych do odrębnego wykorzystania w odniesieniu do kierunku  $x$  i kierunku  $y$ . W tym celu zbiór danych podzielno na dwie części: drgania pomierzone tylko w kierunku  $x$  oraz drgania pomierzone tylko w kierunku  $y$ . Na rys. 4.21, rys. 4.22, rys. 4.23 przedstawiono procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek osobno w kierunku  $x$  (a) oraz osobno kierunku  $y$  (b) w przypadku uczenia, walidacji oraz testowania.



Rys. 4.21. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku uczenia: a)  $r_{vx}$  oraz b)  $r_{vy}$



Rys. 4.22. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku walidacji: a)  $r_{vx}$  oraz b)  $r_{vy}$



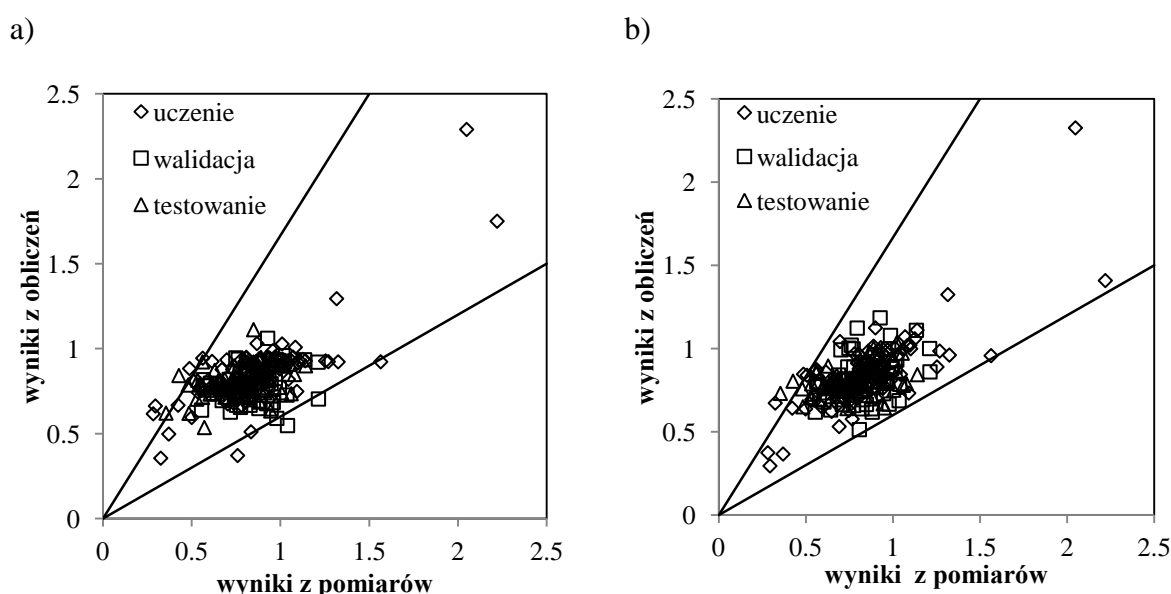
Rys. 4.23. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku testowania: a)  $r_{vx}$  oraz b)  $r_{vy}$

Z analizy wszystkich uzyskanych rezultatów wynika, że w przypadku prognozowania wartości ułamka  $r_v$  najlepsze wyniki uzyskano z użyciem SSN 35 oraz SSN 39, w przypadku których uzyskano najmniejsze błędy  $MSE$  uczenia, walidacji i testowania oraz największy procent sukcesu  $SR$ . Wektory wejścia SSN 35 oraz SSN 39 zostały zbudowane z następujących parametrów: SSN 35 –  $x_{vy(5x1)} = \{v_{ygmax}, En, r_e, X, Y\}$ , SSN 39 –  $x_{vy(6x1)} = \{v_{ygmax}, En, r_e, X, Y, f_{lgv}\}$ . Natomiast najmniejszy procent sukcesu  $SR$  neuronowego prognozowania przekazywania składowych prędkości drgań z gruntu na budynek uzyskano w przypadku kierunku  $y$ , dla SSN 30 o wektorze wejścia  $x_{vy(4x1)} = \{v_{ygmax}, En, r_e, f_{lgv}\}$ . Przykładowo w zbiorze uczącym otrzymano  $SR(40\%) = 94\%$  w przypadku SSN 35,  $SR(30\%) = 92\%$  w przypadku SSN 39 oraz w przypadku SSN 30 –  $SR(30\%) = 88\%$ .

Analizując prognozowanie przekazywania drgań tylko w kierunku  $x$ , najlepsze wyniki uzyskano w przypadku SSN 29, natomiast najmniejszy procent sukcesu  $SR$  uczenia, walidacji oraz testowania uzyskano w przypadku SSN 34. Sieci SSN 29 zadano wektor wejścia w postaci  $x_{vx(4x1)} = \{v_{xgmax}, En, r_e, f_{lgv}\}$ , natomiast SSN 34 –  $x_{vx(5x1)} = \{v_{xgmax}, En, r_e, X, Y\}$ .

Porównując wyniki prognozowania przekazywania prędkości drgań poziomych z podłoża na fundament budynku równocześnie w kierunku  $x$  i  $y$ , osobno w kierunku poprzecznym  $x$  oraz osobno w kierunku podłużnym  $y$ , największe dokładności uzyskano w przypadku kierunku  $y$ . Kierunek  $y$  jest zatem stosunkowo dobrze „przewidywalny”. Największe błędy przy wyliczaniu ułamka  $r_v$  za pomocą techniki neuronowej pojawiają się przy próbie „łącznego” uwzględnienia obu kierunków drgań co jest wynikiem znacznych różnic w sposobie przekazywania drgań w kierunku  $x$  i  $y$  (a tym samym we wzorcach im odpowiadających) – analogiczny wniosek sformułowano już w odniesieniu do składowych przyspieszeń drgań.

Na rys. 4.24 przedstawiono wartości ułamka  $r_{vy}$  wyznaczone na podstawie pomiarów i obliczone za pomocą sieci, dla których uzyskano najlepsze wyniki: SSN 35 oraz SSN 39. Zaznaczono granicę błędu względnego  $ep=40\%$ .



Rys. 4.24. Wartość ułamka  $r_{vy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą sieci:  
a) SSN 35, b) SSN 39

#### 4.2.4. Analiza przekazywania wypadkowych prędkości drgań

Wyboru optymalnych sieci z najmniejszymi błędami  $MSE$  uczenia, walidacji oraz testowania dokonano w wyniku wielu analiz. W tabeli 4.5 zamieszczono informacje dotyczące architektury sieci oraz liczby wzorców uczących ( $L$ ), walidujących ( $V$ ) i testujących ( $T$ ), a także podano liczbę epok uczenia i błędy  $MSE$ . Są to sieci do


prognozowania przekazywania wypadkowych prędkości drgań. Numeracja sieci jest zgodna z zestawieniem przedstawionym w tabeli 4.1, gdzie zawarto informację o uwzględnionych parametrach wektora wejścia oraz wyjścia.

Tabela 4.5


Liczba wzorców, architektura i błędy *MSE* zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania wypadkowych prędkości drgań

Nr wariantu wektora wejścia	Liczba wzorców			Architektura sieci	Liczba epok uczenia	<i>MSE</i>		
	<i>L</i>	<i>V</i>	<i>T</i>			<i>L</i>	<i>V</i>	<i>T</i>
41	113	56	57	3-6-1	40	0,0052	0,0049	0,0020
42	113	56	57	4-11-1	40	0,0068	0,0049	0,0020
43	113	56	57	5-7-1	50	0,0034	0,0049	0,0032


Na rys. 4.25, rys. 4.26 oraz rys. 4.27 przedstawiono procent sukcesu *SR* neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek odpowiednio w przypadku uczenia, walidacji oraz testowania proponowanych sieci SSN 41, SSN 42, SSN 43.



Rys. 4.25. Procent sukcesu *SR* neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku uczenia



Rys. 4.26. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku walidacji

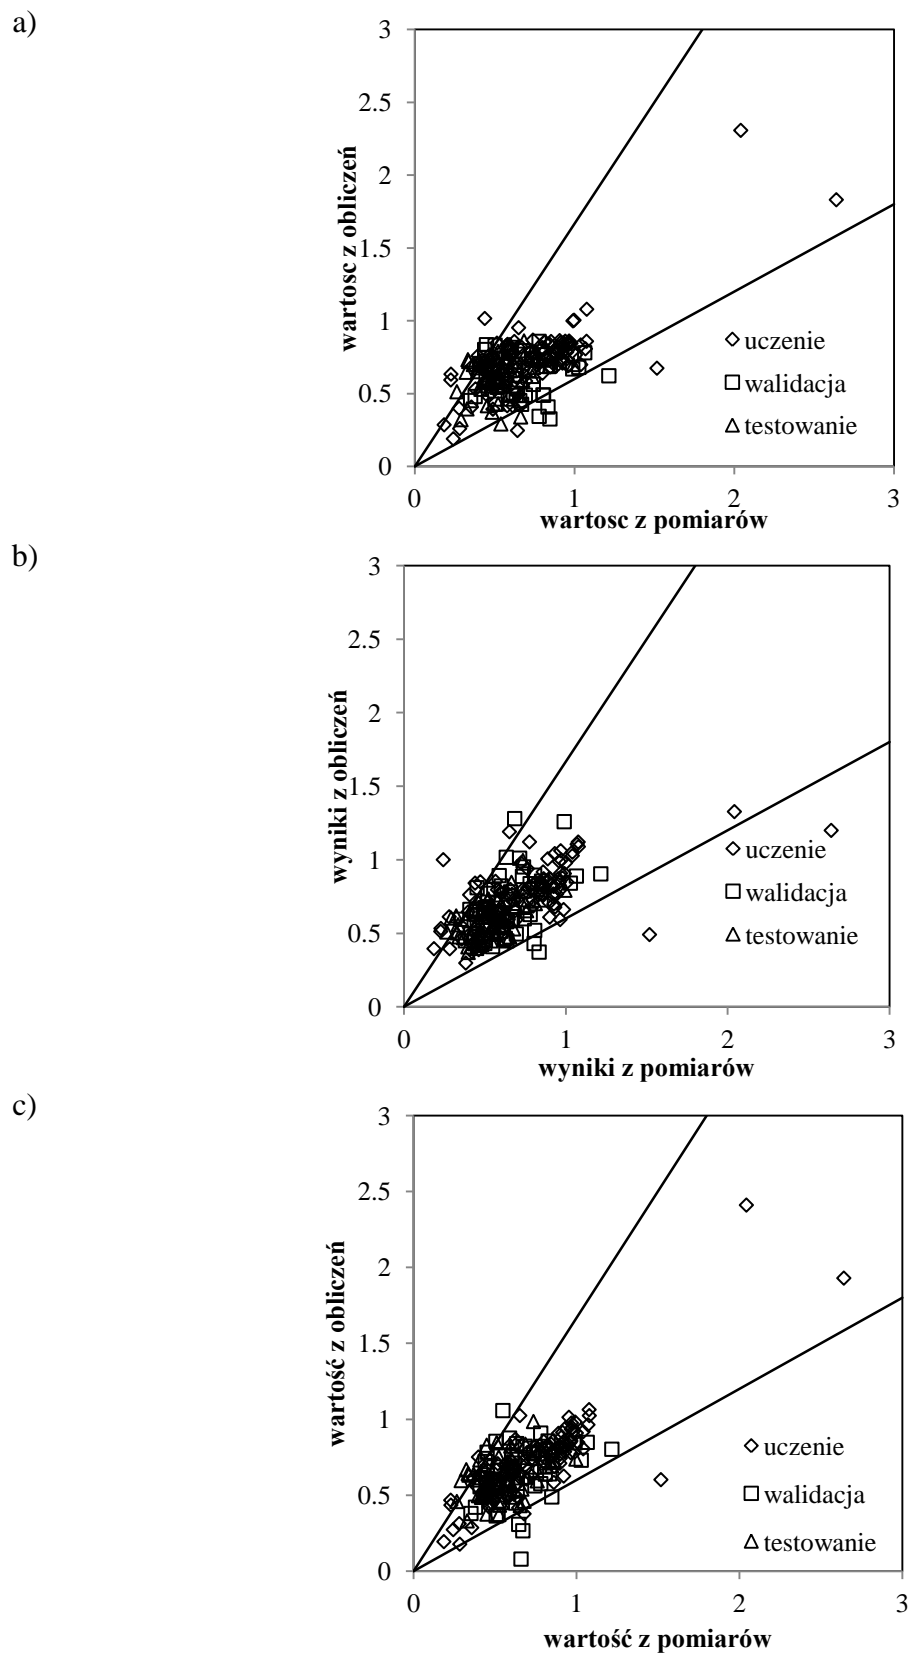


Rys. 4.27. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku testowania

Z przeprowadzonych analiz wynika, że najlepsze wyniki uzyskano w przypadku SSN 43 (najmniejsze błędy  $MSE$  uczenia, walidacji i testowania oraz największy procent sukcesu  $SR$ ). Wektor wejściowy SSN 43 został zbudowany z następujących parametrów:  $x_{wv(5 \times 1)} = \{PGV, En, r_e, X, Y\}$ . Można zauważyć, że zdecydowanie lepsze wyniki uzyskano w przypadku wzbogacenia informacji w wektorze wejścia o parametry takie jak współrzędne seismologiczne  $X$  i  $Y$ . Przykładowo w zbiorze uczącym otrzymano:  $SR(30\%) = 72\%$  w przypadku SSN 41 ( $x_{wv(3 \times 1)} = \{PGV, En, r_e\}$ ),  $SR(30\%) = 77\%$ ,  $SR(30\%) = 80\%$  odpowiednio w przypadku SSN 42 ( $x_{wv(4 \times 1)} = \{PGV, En, X, Y\}$ ) i SSN 43 ( $x_{wv(5 \times 1)} = \{PGV, En, r_e, X, Y\}$ ). Rys. 4.28 porównuje wartości ułamka  $r_{wv}$  wyliczone na podstawie pomiarów



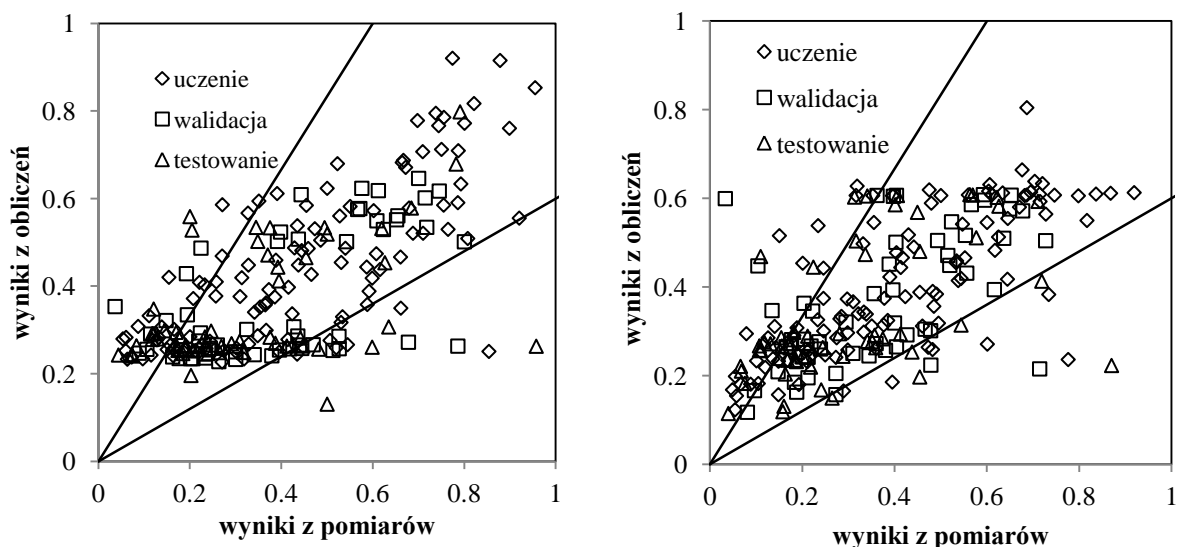
i obliczone za pomocą SSN 41 (a), SSN 42 (b), SSN 43 (c). Zaznaczono granicę błędu względnego  $ep=40\%$ .



Rys. 4.28. Wartość ułamka  $r_{wv}$  wyznaczona na podstawie pomiarów i obliczona za pomocą:  
a) SSN 41, b) SSN 42, c) SSN 43

### 4.3. Wyniki obliczeń z użyciem sieci neuronowych z regularyzacją oraz bayesowskich sieci neuronowych

Do prognozowania przekazywania się drgań z gruntu na fundament budynku zastosowano również sieci neuronowe z regularyzacją. Analizowano sieci z jedną warstwą ukrytą z regularyzacją i z algorytmem uczenia LM. Przykładowo, po przeprowadzeniu wielu analiz tego typu sieci – z różną liczbą neuronów w warstwie ukrytej i różnymi wartościami współczynnika regularyzacji  $\gamma$  – w przypadku prognozowania ułamka  $r_{WA}$  na podstawie energii wstrząsu, odległości epicentralnej i maksymalnej wartości wypadkowego przyspieszenia na gruncie (wektor wejścia  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$  i wektor wyjścia  $y_{wa(1 \times 1)} = \{r_{WA}\}$  por. nr 19 w tabeli 4.1), zdecydowano się na wykorzystanie sieci o architekturze 3-40-1 uczoney przez 40 epok i regularyzacji  $\gamma=0,05$ . Jej użycie prowadzi do następujących błędów:  $MSE(L)=0,0210$ ;  $MSE(V)=0,0256$ ;  $MSE(T)=0,0275$ . Rys. 4.29 przedstawia porównanie wartości ułamka  $r_{WA}$  wyznaczonych na podstawie pomiarów i obliczeń za pomocą sieci o takich samych wektorach wejścia i wyjścia: a) sieci 3-40-1, 10 epok uczenia z regularyzacją (SSN + reg.) oraz b) standardowej sztucznej sieci neuronowej (SSN) o strukturze 3-3-1, 40 epok uczenia. Zaznaczono granicę błędu względnego  $ep=40\%$ .




Rys. 4.29. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczeń za pomocą:  
a) sieci 3-40-1, 10 epok uczenia z regularyzacją,  $MSE(L) = 0,0210$ ;  
 $MSE(V) = 0,0256$ ;  $MSE(T) = 0,0275$ ;  
b) SSN o strukturze 3-3-1, 40 epok uczenia  $MSE(L) = 0,0222$ ;  
 $MSE(V) = 0,0241$ ;  $MSE(T) = 0,0266$


Na rys. 4.30 porównano procent sukcesu  $SR$  sieci 3-40-1 z regularyzacją oraz SSN o strukturze 3-3-1. Wyniki otrzymane z obu sieci można uznać za zbliżone z tym, że sieć z regularyzacją uczona jest zaledwie przez 10 epok i przy jej użyciu uzyskano nieco mniejszy procent sukcesu  $SR$ . Niemniej jednak sieć z regularyzacją wymaga dodatkowych prac

związanych z analizą wielkości błędu  $MSE$  w zależności od współczynnika regularyzacji  $\gamma$ . Należy zwrócić uwagę, iż w przypadku sieci z regularyzacją konieczne jest wykorzystanie znacznie większej liczby neuronów w warstwie ukrytej.


a)



b)

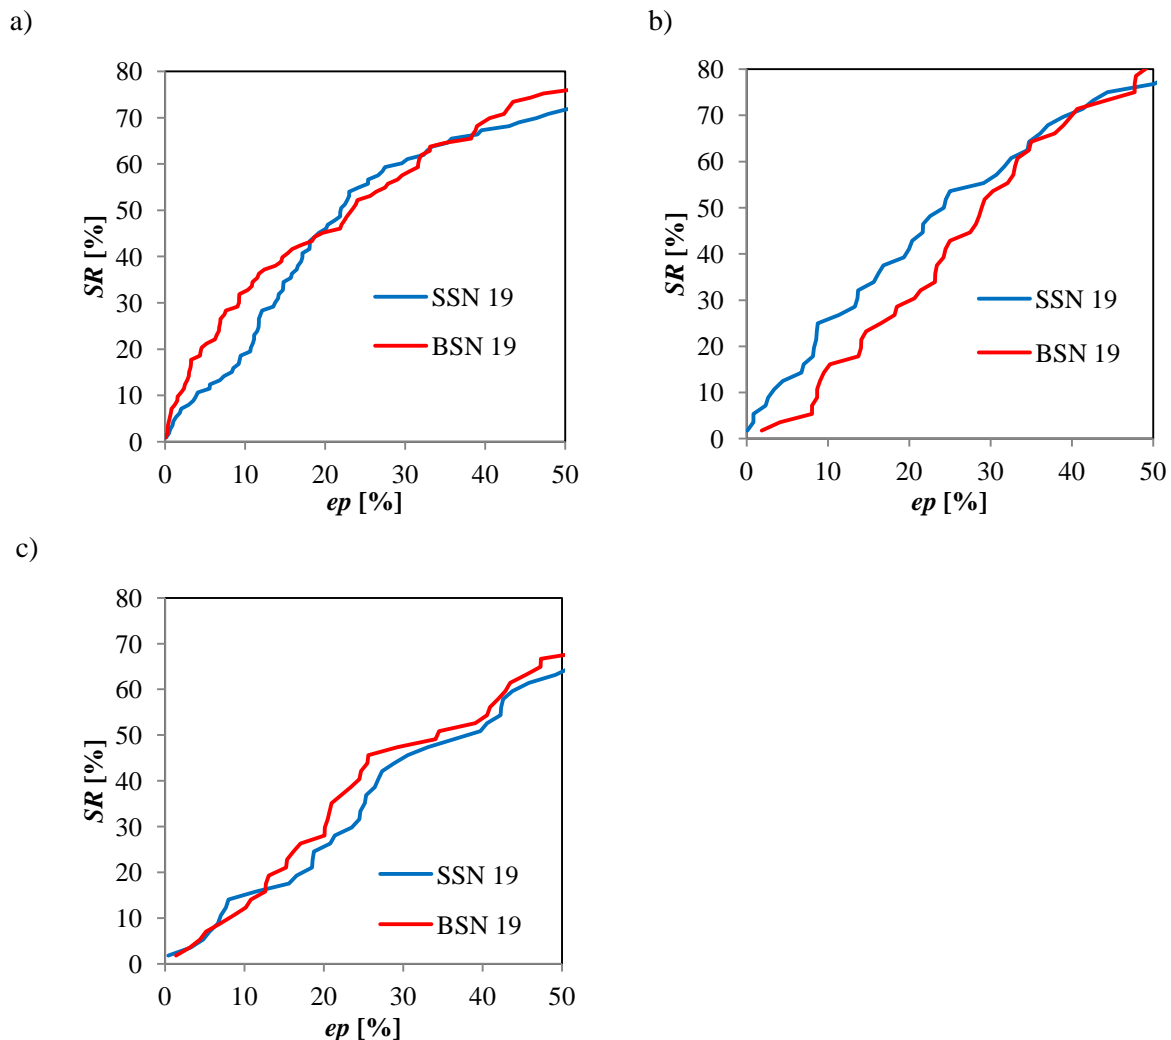


c)




Rys. 4.30 Procent sukcesu  $SR$  neuronowej prognozy (SSN i SSN + reg.) przekazywania wypadkowych przyspieszeń drgań z gruntu na budynek w przypadku: a) uczenia, b) walidacji, c) testowania

W niniejszej pracy dodatkowo zdecydowano się na rozważenie wykorzystania bayesowskich sztucznych sieci neuronowych. Na rys. 4.31 porównano wyniki uzyskane z użyciem standardowej sztucznej sieci neuronowej oraz bayesowskiej sieci neuronowej z wariantem wektora wejścia nr 19 (BSN 19) do prognozowania przekazywania wypadkowych przyspieszeń drgań z gruntu na fundament budynku. Wektor wejścia tej sieci ma postać:  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$ . Analiza wielu wersji architektury bayesowskich sieci neuronowych w przypadku BSN 19, prowadzi do wyboru sieci z 46 neuronami w warstwie ukrytej, uczonej przez 80 epok. Ww. sieć „pracuje” przy tylko 37 aktywnych parametrach. W przypadku sieci o architekturze 3 - 46 - 1 uzyskano najmniejszy błąd średniokwadratowy uczenia, walidacji oraz testowania:  $MSE(L) = 0,0181$ ;  $MSE(V) = 0,0221$ ;  $MSE(T) = 0,0221$ . Odpowiednie błędy standardowej sztucznej sieci neuronowej o takim samym wektorze wejścia ( $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$ ) w każdym ze zbiorów (uczącym, walidującym, testującym) były większe:  $MSE(L) = 0,0222$ ;  $MSE(V) = 0,0241$ ;  $MSE(T) = 0,0266$ .



Rys. 4.31. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych przyspieszeń drgań z gruntu na budynek w przypadku wykorzystania SSN 19 oraz BSN 19: a) uczenie, b) walidacja, c) testowanie

Na rys. 4.32 przedstawiono porównanie wyników uzyskanych z użyciem bayesowskiej sieci neuronowej o wektorze wejścia  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$  (BSN 19) z obliczonymi na podstawie pomiarów. Analogiczny wykres dotyczący ułamka  $r_{WA}$  w przypadku obliczeń z zastosowaniem standardowej sztucznej sieci neuronowej SSN19 zaprezentowano na rys. 4.15 a.

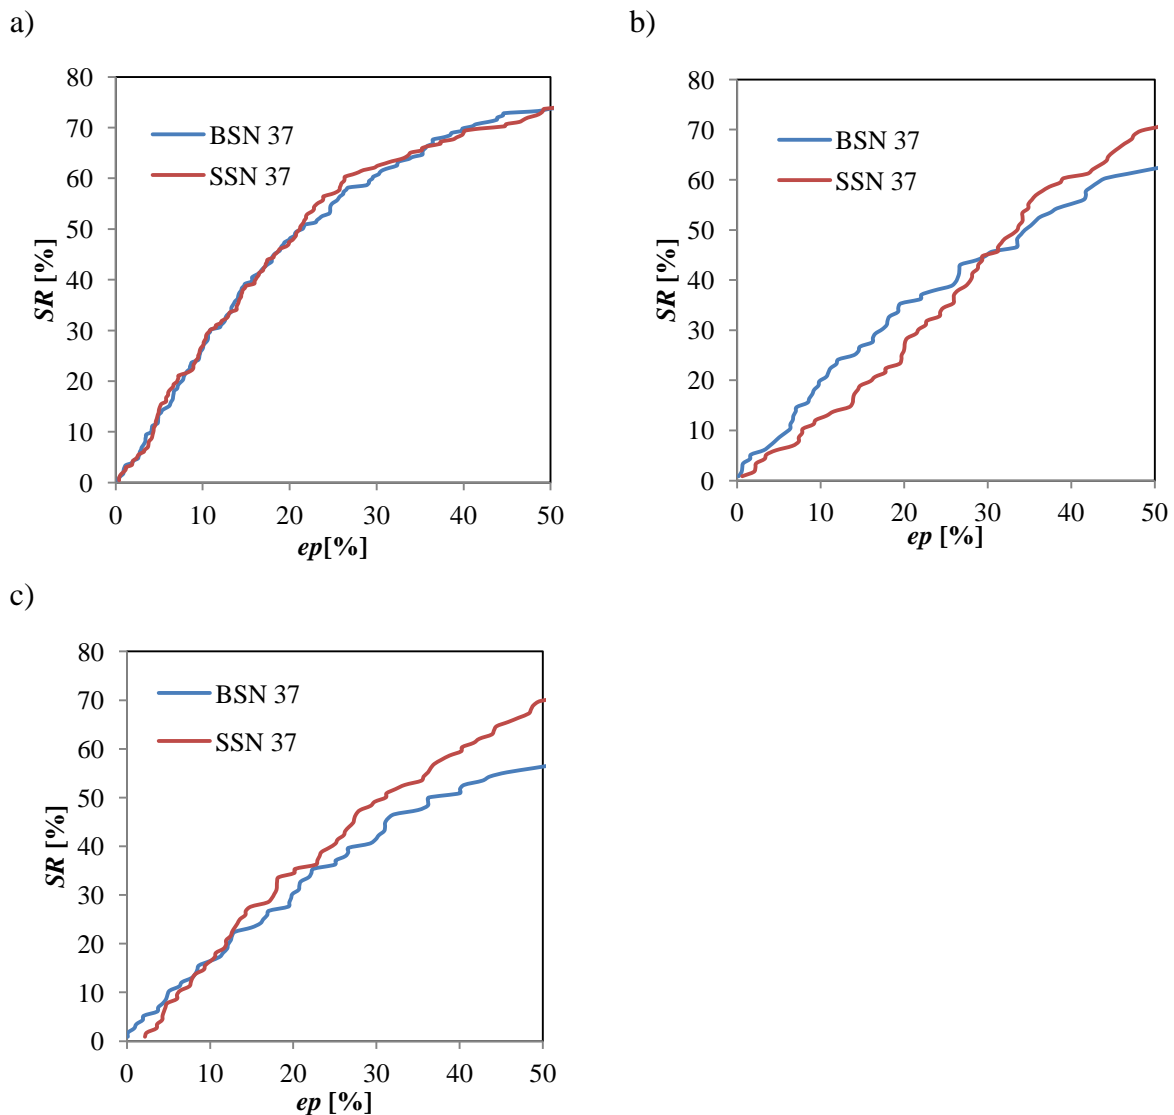


Rys. 4.32. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczeń za pomocą sieci BSN 19, 3-46-1, 80 epok uczenia

Z analizy rezultatów uzyskanych z wykorzystaniem standardowych sztucznych sieci neuronowych oraz bayesowskich sieci neuronowych, wynika iż w przypadku prognozowania ułamka  $r_{WA}$  nieznacznie lepsze dane uzyskujemy przy użyciu bayesowskich sieci neuronowych dla których uzyskano najmniejsze błędy  $MSE$  uczenia, testowania oraz większy procent sukcesu  $SR$ . Przykładowo w przypadku standardowej sztucznej sieci neuronowej SSN 19 uzyskano odpowiednio w zbiorach uczącym oraz testującym:  $SR(30\%) = 61\%$ ,  $SR(30\%) = 45\%$ . Natomiast w przypadku bayesowskiej sztucznej sieci neuronowej BSN 19 uzyskano następujący procent sukcesu w przypadku zbioru uczącego oraz testującego:  $SR(30\%) = 58\%$ ,  $SR(30\%) = 47\%$ .

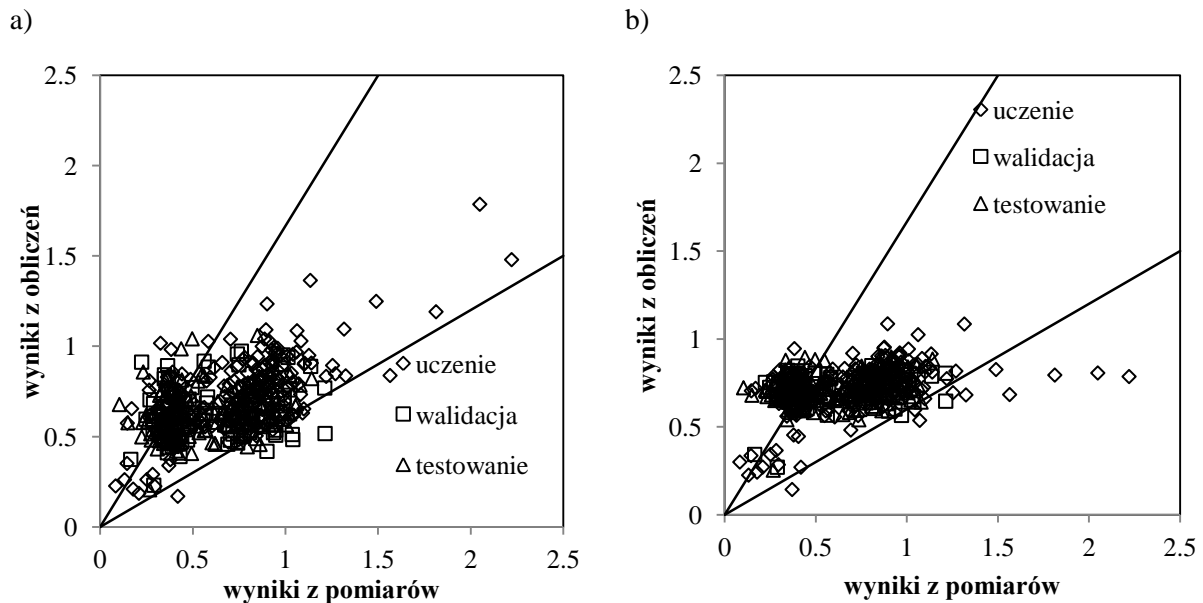
Analogiczne rozważania przeprowadzono w przypadku porównywania sieci do prognozowania przekazywania składowych prędkości drgań równocześnie pomierzonych w kierunku  $x$  i  $y$ . Również stwierdzono niewielkie różnice pomiędzy wynikami uzyskanymi w przypadku standardowej sztucznej sieci neuronowej oraz bayesowskiej sieci neuronowej. Analizie poddano BSN 37 o wektorze wejścia  $x_{vxy(6 \times 1)} = \{v_{gmax}, En, r_e, X, Y, f_{gl}\}$  oraz wektorze wyjścia  $y_{vxy(1 \times 1)} = \{r_{vxy}\}$ . Na rys. 4.33 przedstawiono porównanie procentu sukcesu  $SR$  neuronowej prognozy przekazywania składowych prędkości drgań łącznie w kierunku  $x$  i  $y$  z gruntu na fundament z użyciem standardowej sztucznej sieci neuronowej oraz

bayesowskiej sieci neuronowej dla uczenia, walidacji oraz testowania. W przypadku bayesowskiej sieci najmniejszy błąd  $MSE$  uczenia, walidacji oraz testowania ( $MSE(L) = 0,0130$ ,  $MSE(V) = 0,0122$ ,  $MSE(L) = 0,0128$ ) uzyskano dla sieci o architekturze 6-27-1 przy 30 epokach uczenia. Ww. sieć „pracuje” przy 18 aktywnych parametrach. Natomiast w przypadku standardowej sztucznej sieci neuronowej najmniejsze błędy średniokwadratowe  $MSE$  uczenia, walidacji oraz testowania uzyskano dla sieci z 12 neuronami w warstwie ukrytej oraz 40 epokami uczenia ( $MSE(L) = 0,0095$ ,  $MSE(V) = 0,0119$ ,  $MSE(L) = 0,0112$ ).



Rys. 4.33. Procent sukcesu  $SR$  neuronowej prognozy przekazywania składowych prędkości drgań z gruntu na budynek w przypadku: a) uczenia, b) walidacji, c) testowania

Przykładowo na rys. 4.34 porównano wyniki uzyskane w przypadku składowych prędkości drgań prognozowanych łącznie w kierunku  $x$  i  $y$  przy użyciu standardowej sztucznej sieci oraz bayesowskiej sieci neuronowej o wektorze wejścia  $x_{vxy(6 \times 1)} = \{v_{gmax}, En, r_e, X, Y, f_{g1}\}$ . Zaznaczono granicę błędy bezwzględnego  $ep = 40\%$ .



Rys. 4.34. Wartość ułamka  $r_{vxy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą:  
a) SSN 19, b) BSN 19

Z uzyskanych wyników (por. np. rys. 4.31 oraz rys. 4.33) nie da się jednoznacznie określić, który z zastosowanych typów sieci daje lepsze przybliżenia w prognozowaniu przekazywania drgań z gruntu na fundament budynku. Zauważono, że w przypadku prognozowania przekazywania prędkości drgań łącznie w kierunku  $x$  i  $y$  w przypadku wariantu wektora wejścia nr 37, lepsze wyniki uzyskano dla standardowej sztucznej sieci neuronowej. Natomiast w przypadku prognozowania ułamka  $r_{WA}$  (BSN 19), nieznacznie lepsze wyniki uzyskano w przypadku bayesowskich sieci neuronowych. W przypadku bayesowskich sieci neuronowych konieczne jest zastosowanie zdecydowanie większej liczby neuronów w warstwie ukrytej, ale nie wszystkie parametry sieci są aktywne.

#### 4.4. Propozycja zastosowania kaskadowych sieci neuronowych

W celu uzyskania dokładniejszych przybliżeń prognozowania przekazywania drgań z gruntu na fundament budynku podjęto próbę wykorzystania kaskadowych sztucznych sieci neuronowych (KSN). Uzyskane rezultaty zostaną szczegółowo przedstawione w przypadku prognozowania przekazywania składowych oraz wypadkowych prędkości drgań z gruntu na fundament budynku. Zastosowano sieci neuronowe o wektorach wejścia  $x_{vxy(7 \times 1)} = \{v_{gmax}, En, r_e, X, Y, f_{lga}, k\}$  (SSN 40, por. tabela 4.1 i 4.4),  $x_{wv(4 \times 1)} = \{PGV, En, X, Y\}$  (SSN 42, por. tabela 4.1 i 4.5) oraz odpowiadającym im wektorach wyjścia. W przypadku prognozowania składowych prędkości drgań na wyjściu z sieci oczekiwano ułamka  $y_{vxy(1 \times 1)} = \{r_{vxy}\}$ , natomiast w przypadku wypadkowych prędkości drgań, oczekiwano ułamka  $y_{wy(1 \times 1)} = \{r_{wv}\}$ . W pierwszym kroku ( $i=1$ ) kaskadowej sztucznej sieci zdecydowano się na architekturę sieci wyznaczoną jak w przypadku standardowej sztucznej sieci neuronowej (zgodnie z tabelą 4.4 i tabelą 4.5).


Należy zauważyć, iż liczba neuronów w warstwie ukrytej ( $H$ ) jest wybierana w pierwszym kroku kaskadowej sieci neuronowej i nie zmienia się w kolejnych krokach. W kolejnym kroku – zaczynając od drugiego – liczba parametrów w wektorze wejścia rośnie, ze względu na jego uzupełnienie wartością ułamka  $r$  wyliczoną w kroku poprzedzającym (por. p. 3.2.4).

W przypadku prognozowania przekazywania składowych prędkości drgań z gruntu na fundament (sieć z wektorem wejścia  $x_{vxy(7 \times 1)} = \{v_{gmax}, En, r_e, X, Y, f_{lga}, k\}$ ), jako pierwszą podstawową sieć przyjęto sieć o architekturze 7-17-1. Natomiast w przypadku prognozowania przekazywania wypadkowych prędkości drgań (sieć z wektorem wejścia  $x_{wv(4 \times 1)} = \{PGV, En, X, Y\}$ ), jako sieć w pierwszym kroku przyjęto sieć o architekturze 4-11-1. W przypadku tych sieci uzyskano odpowiednio błędy dla uczenia, walidacji oraz testowania:  $MSE(L) = 0,0089$ ;  $MSE(V) = 0,0058$ ;  $MSE(T) = 0,0053$  oraz  $MSE(L) = 0,0068$ ;  $MSE(V) = 0,0049$ ;  $MSE(T) = 0,0030$ . Jest to pierwszy krok ( $i=1$ ) kaskadowej sieci neuronowej. W kolejnych krokach zastosowano odpowiednio sieci neuronowe o architekturach 8-17-1 w przypadku składowych prędkości drgań oraz 5-11-1 w przypadku wypadkowych prędkości drgań.


Na rys. 4.35 przedstawiono porównanie procentu sukcesu  $SR$  w poszczególnych krokach kaskadowej sieci neuronowej w przypadku sieci do prognozowania ułamka  $r_{vxy}$  dla uczenia, walidacji oraz testowania.




a)



b)

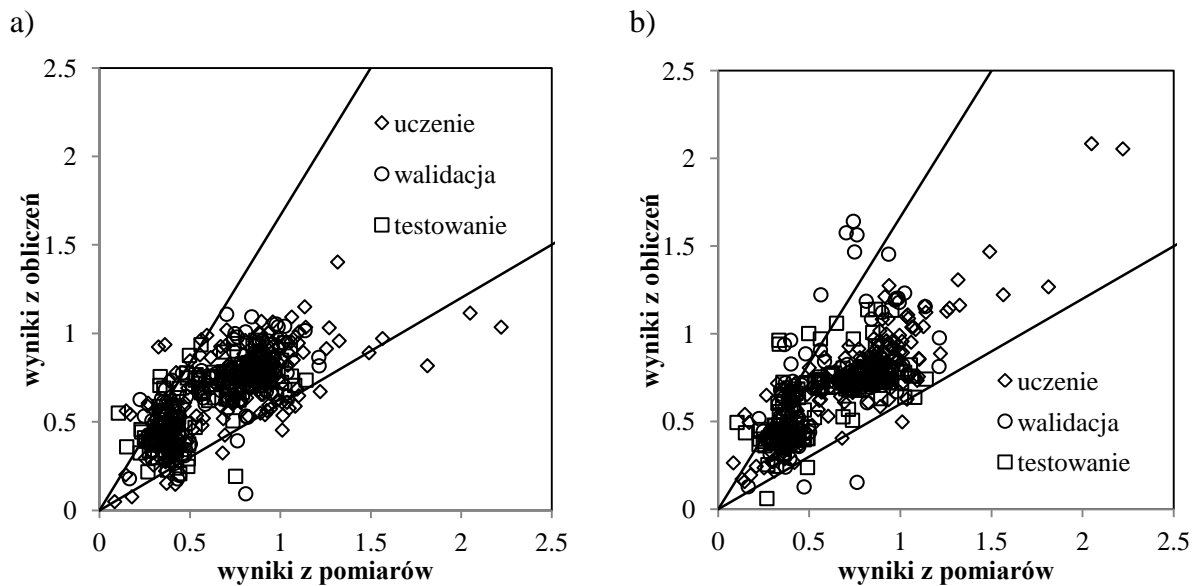


c)



Rys. 4.35. Procent sukcesu  $SR$  neuronowej prognozy przekazywania składowych prędkości drgań z użyciem sieci kaskadowej dla: a) uczenia, b) walidacji, c) testowania


Analizując wyniki kolejnych iteracji przy prognozowaniu przekazywania składowych prędkości drgań z gruntu na fundament budynku stwierdzono, iż zaproponowany sposób obliczeń może korzystnie wpłynąć na poprawę dokładności aproksymacji, zarówno w przypadku zbioru: uczącego, walidującego jak i testującego. Rys. 4.36 przedstawia porównanie wartości ułamka  $r_{vy}$  wyliczonego na podstawie pomiarów i obliczeń za pomocą sieci kaskadowej w kroku nr 1 (a) oraz w kroku nr 10 (b).




Rys. 4.36. Wartość ułamka  $r_{vy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą kaskadowej sieci neuronowej: a) krok nr 1, b) krok nr 10

W przypadku sieci o wektorze wejścia  $x_{wv(4 \times 1)} = \{PGV, En, X, Y\}$  i wektorze wyjścia  $y_{wy(1 \times 1)} = \{r_{wv}\}$  zdecydowano się na zwiększenie zbioru uczącego, zaczynając od kroku 2 ( $i > 1$ ), o wzorce znajdujące się do tej pory w zbiorze walidującym. Jest to spowodowane brakiem konieczności projektowania sieci w poszczególnych krokach, gdyż architektura sieci została dobrana w kroku 1. Zatem liczba wzorców uczących wynosi  $L_{i > 1} = L + V$ . W związku z tym nowy zbiór uczący zawiera teraz 75 % wszystkich wzorców, a zbiór testujący pozostałe 25 % wzorców. Na rys. 4.37 przedstawiono procent sukcesu  $SR$  w przypadku sieci do prognozowania ułamka  $r_{wv}$ .

a)

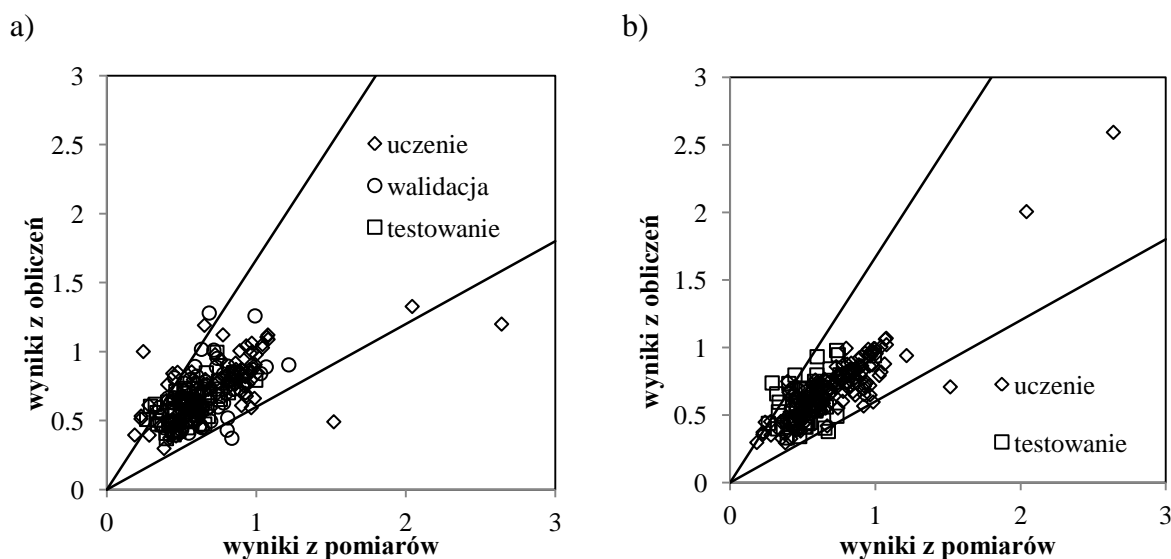


b)



Rys. 4.37. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na fundament budynku w przypadku kaskadowych sieci dla: a) uczenia, c) testowania

Przeprowadzona analiza prowadzi do wniosku, że zastosowanie układu kaskadowego sieci neuronowych może powodować zwiększenie dokładności uzyskanych wyników. Analizując wpływ kolejnych iteracji na dokładność prognozowania wypadkowych prędkości przekazywania drgań z gruntu na fundament budynku. Stwierdzono, iż w przypadku uczenia sieci o wektorze wejścia  $x_{wv(4x1)} = \{PGV, En, X, Y\}$  już 12 kroków iteracji skutkuje znacznym zwiększeniem procentu sukcesu  $SR$ . Rys. 4.38 przedstawia porównanie wartości ułamka  $r$  wyliczonego na podstawie pomiarów i obliczeń za pomocą sieci kaskadowej do prognozowania przekazywania wypadkowych prędkości drgań w przypadku kroku nr 1 (a) oraz kroku nr 12 (b). Zaznaczono granice błędu względnego  $ep = 40\%$ .




Rys. 4.38. Wartość ułamka  $r_{wv}$  wyznaczona na podstawie pomiarów i obliczona za pomocą kaskadowej sieci neuronowej: a) krok nr 1, b) krok nr 12

#### 4.5. Wnioski


Z analizy wyników badań doświadczalnych widać, że ocena przekazywania drgań od wstrząsów górniczych z gruntu na budynek o średniej wysokości, niesie wiele trudności z uwagi na niejednoznaczność tego procesu. Można jedynie poszukiwać pewnych zależności ułamka  $r$  od parametrów drgań gruntu i wstrząsów, natomiast określenie precyzyjnych trendów jest niemożliwe. Dodatkowym problemem jest duży rozrzut wartości ułamka  $r$  w przypadku interakcji dynamicznej podłoże – budynek.

Wykorzystując wyniki badań doświadczalnych, podjęto próbę zastosowania sztucznych sieci neuronowych (SSN) do przewidywania sposobu przekazywania się drgań od wstrząsów górniczych z gruntu na fundament pięciokondygnacyjnego budynku mieszkalnego oraz oceny istotności wpływu poszczególnych parametrów na redukcję drgań fundamentu budynku. Przeprowadzono analizę wielu sztucznych sieci neuronowych do prognozowania przekazywania przyspieszeń oraz prędkości drgań z gruntu na fundament budynku. Analizie poddano składowe prędkości i przyspieszenia drgań oraz wypadkowe przyspieszenia i prędkości drgań. Projektowano sieci w celu uzyskania jak najdokładniejszych przybliżeń ułamków  $r$ . Na rys. 4.39, rys. 4.40, rys. 4.41 porównano procenty sukcesu  $SR$  sieci dla których uzyskano najlepsze wyniki w przypadku prognozowania składowych przyspieszeń oraz prędkości drgań odpowiednio w kierunku poprzecznym  $x$ , w kierunku podłużnym  $y$  oraz równocześnie w kierunku  $x$  i  $y$ .


a)



b)




c)




Rys. 4.39 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 13 oraz SSN 16 do prognozowania składowych prędkości oraz przyspieszeń drgań w kierunku  $x$  dla: a) uczenia, b) walidacji c) testowania


a)



b)

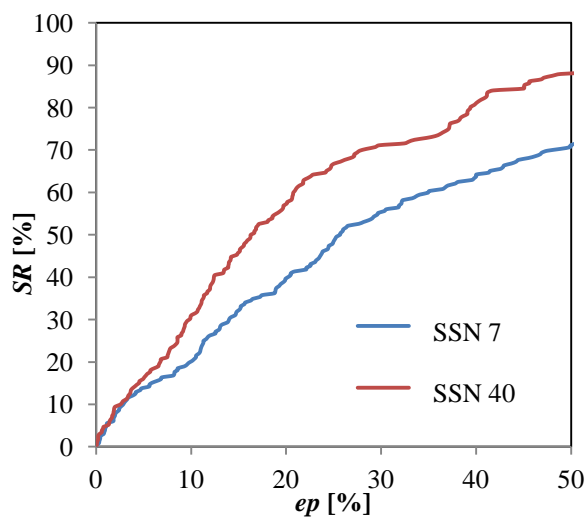


c)




Rys. 4.40 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 6 oraz SSN 39 do prognozowania składowych prędkości oraz przyspieszeń drgań w kierunku  $y$  dla: a) uczenia, b) walidacji c) testowania


a)



b)




c)




Rys. 4.41 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 7 oraz SSN 40 do prognozowania składowych prędkości oraz przyspieszeń drgań łącznie w kierunku  $x$  i  $y$  dla: a) uczenia, b) walidacji c) testowania

Stwierdzono, iż we wszystkich analizowanych przypadkach prognozowania składowych przyspieszeń oraz prędkości drgań z gruntu na fundament budynku mieszkalnego większe dokładności uzyskano w przypadku prędkości drgań. Za każdym razem w przypadku sieci do prognozowania składowych prędkości drgań uzyskiwano większy procent sukcesu  $SR$  oraz mniejsze błędy  $MSE$  dla uczenia, walidacji oraz testowania.


a)



b)



c)



Rys. 4.42 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku w przypadku SSN 20 oraz SSN 43 do prognozowania wypadkowych prędkości oraz przyspieszeń drgań dla: a) uczenia, b) walidacji c) testowania



Analogiczne wnioski dotyczą prognozowania przekazywania wypadkowych przyspieszeń oraz wypadkowych prędkości drgań z podłoża na fundament budynku. Na rys. 4.42 a, b, c porównano procent sukcesu  $SR$  uczenia, walidacji oraz testowania w przypadku ułamków  $r_{WA}$  oraz  $r_{WV}$ .

W związku z trudnościami, jakie występują, w prognozowaniu różnic w jednocześnie trwających drganiach gruntu i fundamentu budynku wydaje się, że zaproponowane standardowe sztuczne sieci neuronowe różnego typu mogą być przydatne do przewidywania redukcji maksymalnych wartości składowych oraz wypadkowych przyspieszeń i prędkości drgań przy przekazywaniu ich z gruntu na budynek o średniej wysokości.

Użycie sieci neuronowych z regularyzacją oraz bayesowskich sieci neuronowych nie powoduje istotnego zwiększenia dokładności aproksymacji neuronowej. Praktycznie wyniki uzyskiwane za pomocą standardowych sieci neuronowych, sieci z regularyzacją oraz bayesowskich sieci neuronowych są zbliżone dla danego wariantu wektor wejścia – wektor wyjścia.

Na osiągnięcie nieco lepszych dokładności pozwala zastosowanie sieci kaskadowych.

## 5. PROPOZYCJE WZORÓW EMPIRYCZNYCH DO OCENY PRZEKAZYWANIA DRGAŃ Z PODŁOŻA NA BUDYNEK

### 5.1. Modele regresji wielokrotnej

Regresja to w statystyce metoda, pozwalająca na zbadanie związku pomiędzy różnymi wielkościami występującymi w danych i wykorzystanie tej wiedzy do przewidywania nieznanych wartości jednych wielkości na podstawie znanych wartości innych [59]. Z matematycznego punktu widzenia, regresją nazywamy dowolną metodę statystyczną pozwalającą estymować warunkową wartość oczekiwaną zmiennej losowej, zwanej zmienną objaśnianą, dla zadanych wartości innej zmiennej lub wektora zmiennych losowych.

Klasyczny model regresji liniowej jest często stosowanym narzędziem do analizy danych empirycznych. Zmienna, której zachowanie wyjaśniamy za pomocą modelu, nazywamy zmienną objaśnianą (zależną), natomiast zmienne, które wykorzystane są do wyjaśnienia – zmiennymi objaśniającymi (niezależnymi) [59]. Korzystając z modelu regresji liniowej obliczamy linię prostą, która najlepiej pasuje do danych, przy pomocy Metody Najmniejszych Kwadratów (MNK).

Najczęściej stosowanym modelem jest model liniowy. W modelu tym zakłada się, że związek między zmienną objaśnianą a zmiennymi objaśniającymi jest liniowy:

$$y_i = x_{1i}\beta_1 + x_{2i}\beta_2 + \dots + x_{Ki}\beta_K + \varepsilon_i, \text{ dla } i = 1, \dots, N, \quad (5.1)$$

przy czym

- $y$  - zmienna zależna (objaśniana),
- $x_1, \dots, x_K$  - zmienne objaśniające (niezależne), zmiennych tych jest  $K$ ,
- $\varepsilon$  - błąd losowy,

Błąd losowy  $\varepsilon$  odpowiada ze tę część zmienności  $y$ , której nie da się wyjaśnić zmiennymi objaśniającymi. W typowych przypadkach jedynie część zmienności zmiennej zależnej można wyjaśnić za pomocą zmienności zmiennych niezależnych. Wielkości parametrów  $\beta_K$  w modelu liniowym są niewiadomymi, które wyliczamy na podstawie danych empirycznych.

Znajdowanie estymatora (oszacowania) MNK parametrów  $(\beta_1, \dots, \beta_K)$  określamy mianem regresji liniowej  $y_i$  na  $x_{1i} \dots x_{Ki}$ . Zgodnie z przyjętą konwencją, oszacowania nieznanych parametrów  $\beta_1, \dots, \beta_K$ , uzyskane za pomocą MNK, oznaczamy zwykle jako  $b_1, \dots, b_K$ . Przewidywane na podstawie oszacowanego modelu wartości zmiennej zależnej nazywamy wartością dopasowaną (teoretyczną):

$$\hat{y}_i = x_{1i}b_1 + x_{2i}b_2 + \dots + x_{Ki}b_K \quad (5.2)$$

Wartości dopasowane różnią się od rzeczywistych wartości  $y_i$ , ponieważ w modelu oszacowanym zamiast prawdziwych (nieznanych) wartości parametru  $\beta_1, \dots, \beta_K$  używamy ich oszacowań  $b_1, \dots, b_K$  i pomijamy błąd losowy.

Reszty definiujemy jako różnicę między wartością zaobserwowaną zmiennej zależnej, a wartością dopasowaną tej zmiennej:

$$e_i = y_i - x_{1i}b_1 - x_{2i}b_2 - \dots - x_{Ki}b_K = y_i - \hat{y}_i \quad (5.3)$$

Relację między resztami, obserwacjami i oszacowaniami parametrów można zapisać w sposób następujący:

$$y_i = \hat{y}_i + e_i = x_{1i}b_1 - x_{2i}b_2 - \dots - x_{Ki}b_K + e_i \quad (5.4)$$

Model jest tym lepiej dopasowany, im mniejsza jest odległość pomiędzy wartością teoretyczną  $\hat{y}_i$  od wartości  $y_i$ . Inaczej mówiąc, najlepiej dopasowanym modelem jest ten, w którym reszty są, co do wartości bezwzględnych, najmniejsze.

Zastosowanie funkcji statystycznych w celu wykonania prostych modeli obliczeniowych jest bardzo często spotykaną i przydatną metodą obliczeniową w praktyce. Takie działania są stosunkowo łatwym i nie wymagającym dużych nakładów pracy sposobem umożliwiającym zbudowanie modelu o zadawalającej dokładności obliczeniowej.

W niniejszej pracy zdecydowano się na opracowanie wzorów empirycznych z zastosowaniem modeli regresji wielokrotnej: liniowej oraz wykładniczej.

## 5.2. Wyniki obliczeń za pomocą wzorów empirycznych

Często przy projektowaniu konstrukcji konieczne jest określenie pewnych parametrów w sposób szybki z zastosowaniem metod przybliżonych. Wygodne jest wówczas wykorzystanie wzorów empirycznych. Mogłyby one w łatwy i szybki sposób pomóc w określeniu przekazywania drgań z gruntu na fundament budynku.

W niniejszym rozdziale przedstawiono obliczenia z zastosowaniem regresji liniowej oraz wykładniczej. Rezultatem tych obliczeń są propozycje empirycznych wzorów do prognozowania przekazywania przyspieszeń oraz prędkości drgań z gruntu na fundament budynku. W opracowaniu wzorów empirycznych wykorzystano te same parametry „wejściowe” jak w przypadku prognozowania przekazywania drgań z gruntu na fundament budynku za pomocą różnych typów sztucznych sieci neuronowych.

W tabeli 5.1 oraz 5.2 przedstawiono wzory empiryczne przygotowane z użyciem odpowiednio regresji liniowej oraz regresji wykładniczej. Zachowano numerację wariantów parametrów „wejściowych” z rozdziału 4.

Tabela 5.1

Wzory empiryczne z zastosowaniem regresji liniowej

	Numer wariantu	Wzór
składowe przyspieszenia drgań	1	$r_{axy}=2,39e^{-10}En+5,02e^{-5}r_e+0,0657a_{gmax}+0,274$
	2	$r_{ax}=2,56e^{-10}En+6,017e^{-5}r_e+0,0121a_{gmax}+0,112$
	3	$r_{ay}=1,516e^{-10}En+5,283e^{-5}r_e+0,0239a_{gmax}+0,371$
	4	$r_{axy}=3,726e^{-10}En+4,31e^{-6}X-8,893e^{-6}Y+0,0296a_{gmax}+0,302$
	7	$r_{axy}=2,196e^{-10}En+5,773e^{-5}r_e+0,0742a_{gmax}-0,0137f_{1ga}+0,519$
	16	$r_{axy}=2,59e^{-10}En+4,88e^{-5}r_e-1,156e^{-6}X-6,764e^{-6}Y-0,0133f_{1ga}+0,0329a_{gmax}+1,213$
	17	$r_{axy}=2,2e^{-10}En+5,2e^{-5}r_e-9,9e^{-6}X-6,52e^{-6}Y-+0,0104f_{1ga}+0,113a_{gmax}+0,756k+0,731$
	18	$r_{axy}=2,4e^{-10}En+6,2e^{-5}r_e-1,118e^{-6}X-6,497e^{-6}Y-0,0099f_{1ga}-+0,0039f_{2ga}+0,122a_{gmax}+0,756k+0,761$
wypadkowe przyspieszenia	19	$r_{WA}=1,473e^{-10}En+8,219e^{-5}r_e+0,117PGA+0,224$
składowe prędkości drgań	22	$r_{vxy}=1,195e^{-10}En+7,84e^{-6}r_e+0,00666v_{gmax}+0,611$
	23	$r_{vx}=1,781e^{-10}En-3,261e^{-6}r_e+0,00888v_{gmax}+0,448$
	24	$r_{vy}=2,3504e^{-11}En+1,96e^{-6}r_e+0,00688v_{gmax}+0,761$
	25	$r_{vxy}=2,185e^{-10}En-2e^{-5}X-3e^{-5}Y+0,00452v_{gmax}+1,464$
	28	$r_{vxy}=1,501e^{-10}En+1,202e^{-6}r_e+0,0045v_{gmax}-0,013f_{g1v}+0,6858$
	36	$r_{vxy}=1,551e^{-10}En+5,136e^{-5}r_e-2,92e^{-5}X-6,34e^{-5}Y-+0,0061v_{gmax}+1,104k+1,255$
	38	$r_{vxy}=2,02e^{-10}En+4,176e^{-5}r_e+0,00279v_{gmax}-2,66e^{-5}X-6,307e^{-5}Y-+0,0127f_{1gv}+1,857$
	40	$r_{vxy}=1,8e^{-10}En+4,2e^{-5}r_e+0,0041v_{gmax}-2,5e^{-5}X-6,1e^{-5}Y-+0,0174f_{1gv}+1,098k+1,183$
wypadkowe prędkości	41	$r_{wv}=3,196e^{-11}En+2,429e^{-5}r_e+0,00701PGV+0,576$
	42	$r_{wv}=2,56e^{-10}En-1,0e^{-5}X-5,0e^{-5}Y-0,0683PGV+1,299$

Tabela 5.2

## Wzory empiryczne z zastosowaniem regresji wykładniczej

	Numer wariantu	Wzór
składowe przyspieszenia	1	$r_{axy}=0,203 \cdot 1^{En} \cdot 1,0001^{re} \cdot 1,096^{agmax}$
	2	$r_{ax}=0,095 \cdot 1^{En} \cdot 1,0003^{re} \cdot 1,754^{agmax}$
	3	$r_{ay}=0,344 \cdot 1^{En} \cdot 1,0001^{re} \cdot 1,305^{agmax}$
	4	$r_{axy}=0,171 \cdot 1^{En} \cdot 1,00001^X \cdot 1,0002^Y \cdot 1,8257^{agmax}$
	7	$r_{axy}=0,528 \cdot 1^{En} \cdot 1,0003^{re} \cdot 1,333^{agmax} \cdot 0,947^{flga}$
	16	$r_{axy}=4,246 \cdot 1^{En} \cdot 1,00013^{re} \cdot 0,999^X \cdot 0,999^Y \cdot 0,949^{slga} \cdot 1,0242^{agmax}$
	17	$r_{axy}=0,805 \cdot 1^{En} \cdot 1,00017^{re} \cdot 0,999^X \cdot 0,999^Y \cdot 0,957^{flga} \cdot 1,329^{agmax} \cdot 11,135^k$
	18	$r_{axy}=0,92 \cdot 1^{En} \cdot 1,00013^{re} \cdot 0,999^X \cdot 0,999^Y \cdot 0,959^{flga} \cdot 0,981^{f2ga} \cdot 1,381^{agmax} \cdot 11,116^k$
wypadkowe przyspieszenia	19	$r_{WA}=0,2033 \cdot 1^{En} \cdot 1,000232^{re} \cdot 1,3341^{PGA}$
składowe prędkości	22	$r_{vxy}=0,5238 \cdot 1^{En} \cdot 1,00003451^{re} \cdot 1,01279^{vgmax}$
	23	$r_{vx}=0,370 \cdot 1^{En} \cdot 1,00003692^{re} \cdot 1,02068^{vgmax}$
	24	$r_{vy}=0,718 \cdot 1^{En} \cdot 1,00003445^{re} \cdot 1,00972^{vgmax}$
	25	$r_{vxy}=1,524 \cdot 1^{En} \cdot 0,999^X \cdot 0,999^Y \cdot 1,0955^{vgmax}$
	28	$r_{vxy}=0,624 \cdot 1^{En} \cdot 1,00001^{re} \cdot 1,0076^{vgmax} \cdot 0,969^{flgv}$
	36	$r_{vxy}=1,102 \cdot 1^{En} \cdot 1,0001^{re} \cdot 0,999^X \cdot 0,999^Y \cdot 1,012^{vgmax} \cdot 7,329^k$
	38	$r_{vxy}=3,086 \cdot 1^{En} \cdot 1,000073^{re} \cdot 1,00517^{vgmax} \cdot 0,999^X \cdot 0,999^Y \cdot 0,971^{flgv}$
	40	$r_{vxy}=0,916 \cdot 1^{En} \cdot 1,00007^{re} \cdot 1,0081^{vgmax} \cdot 0,999^X \cdot 0,999^Y \cdot 0,973^{flgv} \cdot 7,22^k$
wypadkowe prędkości	41	$r_{WV}=0,516 \cdot 1^{En} \cdot 1,000061^{re} \cdot 1,012^{PGV}$
	42	$r_{WV}=01,296 \cdot 1^{En} \cdot 0,999^X \cdot 0,999^Y \cdot 1,012^{PGV}$

W tabeli 5.3 zestawiono wartości błędów  $MSE$ , odpowiadające wzorom empirycznym, do tworzenia których wykorzystano regresję liniową oraz wykładniczą. Błędy wyliczono

w odniesieniu do wartości ułamków  $r$  wyznaczonych na podstawie wyników z badań doświadczalnych wykonanych w skali naturalnej.

Tabela 5.3

Błędy  $MSE$  poszczególnych wzorów empirycznych

	Numer wariantu	Błąd $MSE$	
		Regresja liniowa	Regresja wykładnicza
składowe przyspieszenia drgań	1	0,0501	0,0599
	2	0,0311	0,0397
	3	0,0344	0,0391
	4	0,0527	0,0684
	7	0,0387	0,0886
	16	0,0362	0,04004
	17	0,0242	0,0313
	18	0,0232	0,0313
wypadkowe przyspieszenia	19	0,0404	0,0474
składowe prędkości drgań	22	0,0834	0,0886
	23	0,0621	0,0686
	24	0,0474	0,0484
	25	0,0821	0,0877
	28	0,0810	0,0886
	36	0,0531	0,0833
	38	0,0785	0,0584
	40	0,0514	0,0556
wypadkowe prędkości	41	0,0577	0,0706
	42	0,0673	0,0709

Analizując błędy  $MSE$  (Tabela 5.3) modeli regresji liniowej oraz regresji wykładniczej stwierdzono, że wartości  $r$  obliczone według różnych modeli są porównywalne. Niemniej jednak w większości przypadków korzystając z modelu liniowego uzyskano nieco mniejsze błędy  $MSE$ . Zauważono również, że wraz ze wzbogaceniem informacji wejściowej, zarówno w przypadku modelu liniowego, jak i modelu wykładniczego uzyskuje się mniejsze błędy średniokwadratowe  $MSE$ .

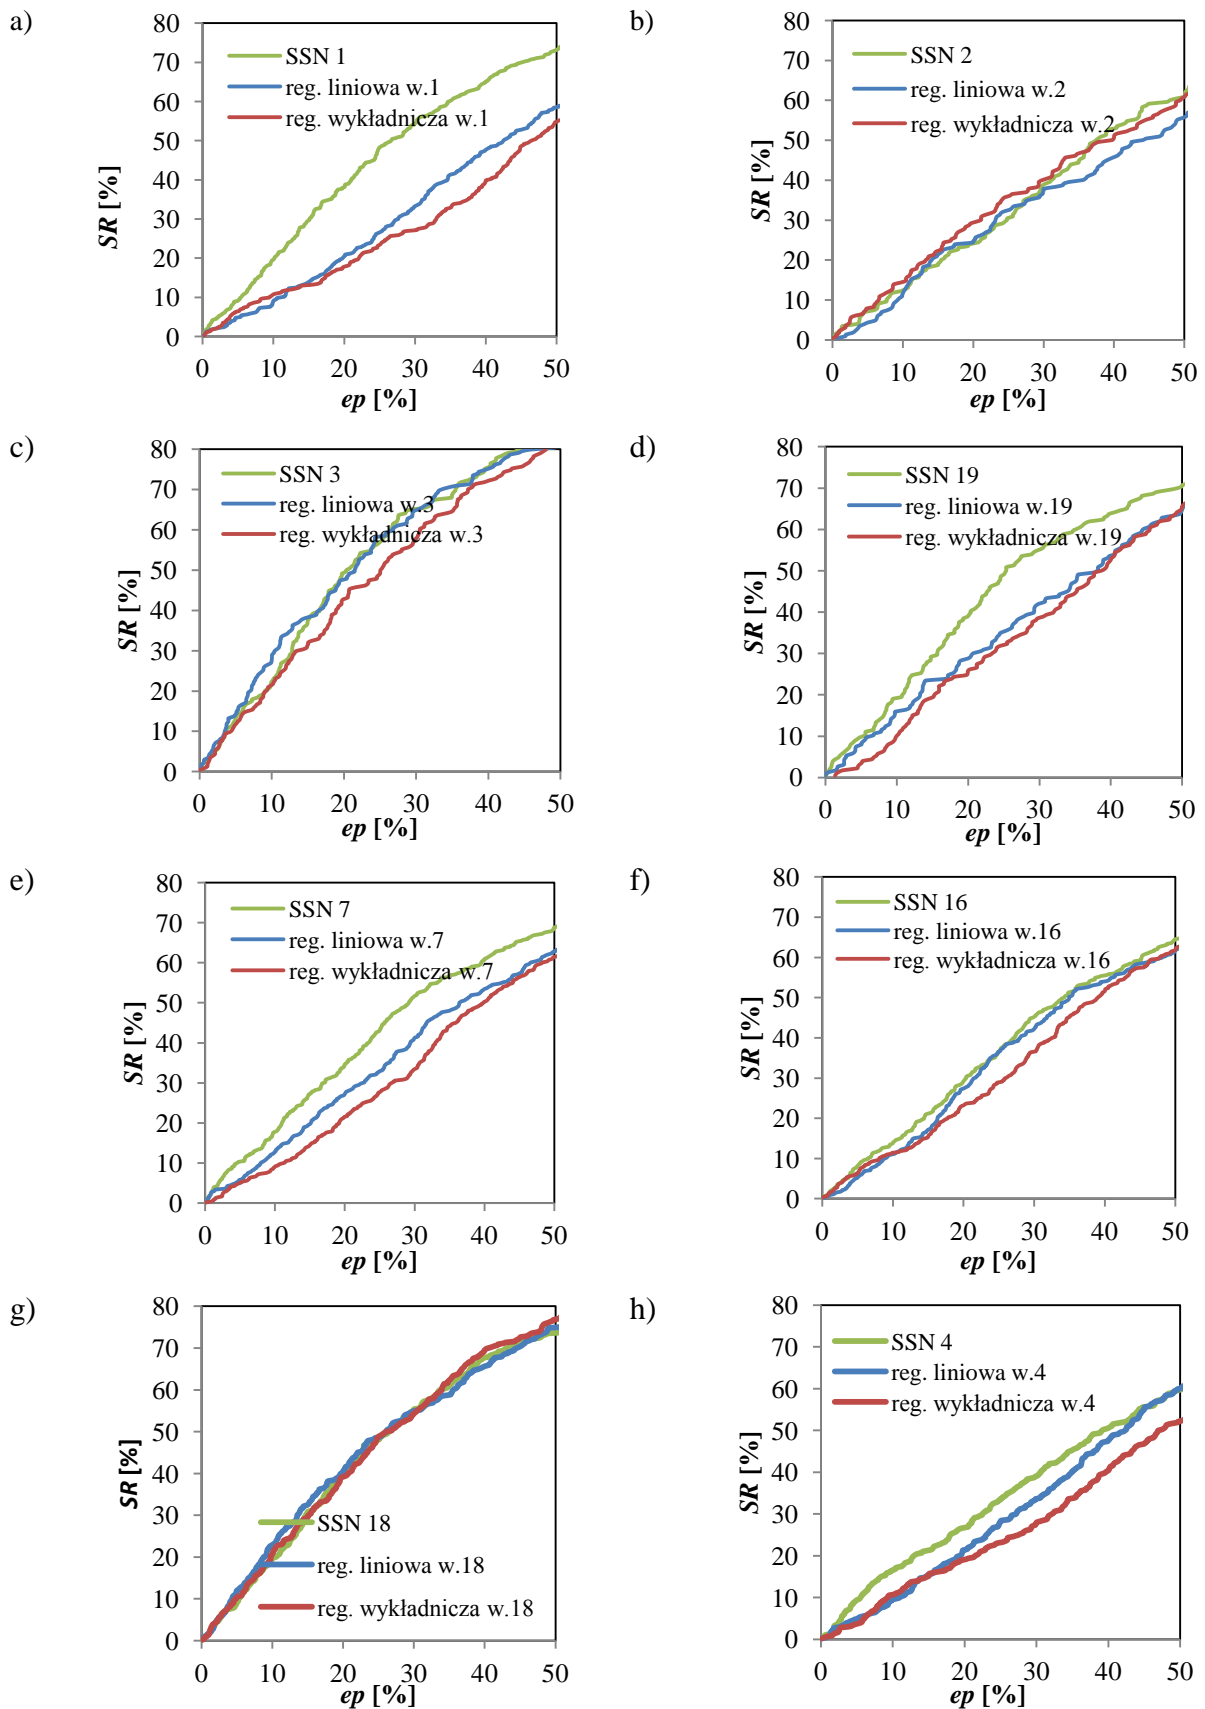
Dodatkowo w celu porównania dokładności przygotowanych wzorów empirycznych, analogicznie jak w przypadku obliczeń z zastosowaniem sztucznych sieci neuronowych, wyliczono procent sukcesu  $SR$  w zależności od błędu bezwzględnego  $ep$ . Na rys. 5.1 (a – h) oraz rys. 5.2 (a – h), odpowiednio w przypadku przyspieszeń oraz prędkości drgań, porównano procent sukcesu  $SR$  wyliczony dla modelu regresji liniowej oraz modelu regresji wykładniczej. Na tych rysunkach, dla porównania, zamieszczono też rezultaty uzyskane w przypadku zaproponowanych sieci neuronowych.

Porównując procent sukcesu  $SR$  prognozowania przekazywania przyspieszeń drgań z gruntu na fundament budynku za pomocą modeli regresji liniowej oraz regresji wykładniczej oraz sztucznych sieci neuronowych stwierdzono, że w większości przypadków lepsze przybliżenia uzyskano w przypadku prognozowaniem ułamka  $r$  za pomocą techniki neuronowej. Zastosowanie sztucznych sieci neuronowych pozwala na uzyskanie większego procentu sukcesu  $SR$  nawet o kilkanaście procent dla danego błędu  $ep$  (por. rys. 5.1 a, d, e, i). Zauważono, iż osiągnięcie porównywalnego przybliżenia z zastosowaniem wzorów empirycznych jest możliwe w przypadku większej liczby parametrów, a co za tym idzie konieczności podania większej ilości informacji (por. rys. 5.1 f, g, h). Porównując wyniki ( $SR$ ) uzyskane w przypadku zastosowania regresji liniowej oraz regresji wykładniczej stwierdzono, iż lepsze przybliżenia uzyskano w przypadku modelu linowego. Niemniej jednak, różnice te są niewielkie.

Analogiczne wyniki, jak w przypadku prognozowania przekazywania przyspieszeń drgań z gruntu na fundament uzyskano w przypadku prognozowania prędkości drgań. Zauważono, że wzory empiryczne mogą być przydatne w przypadku dużej liczby parametrów wejściowych użytych do obliczeń.

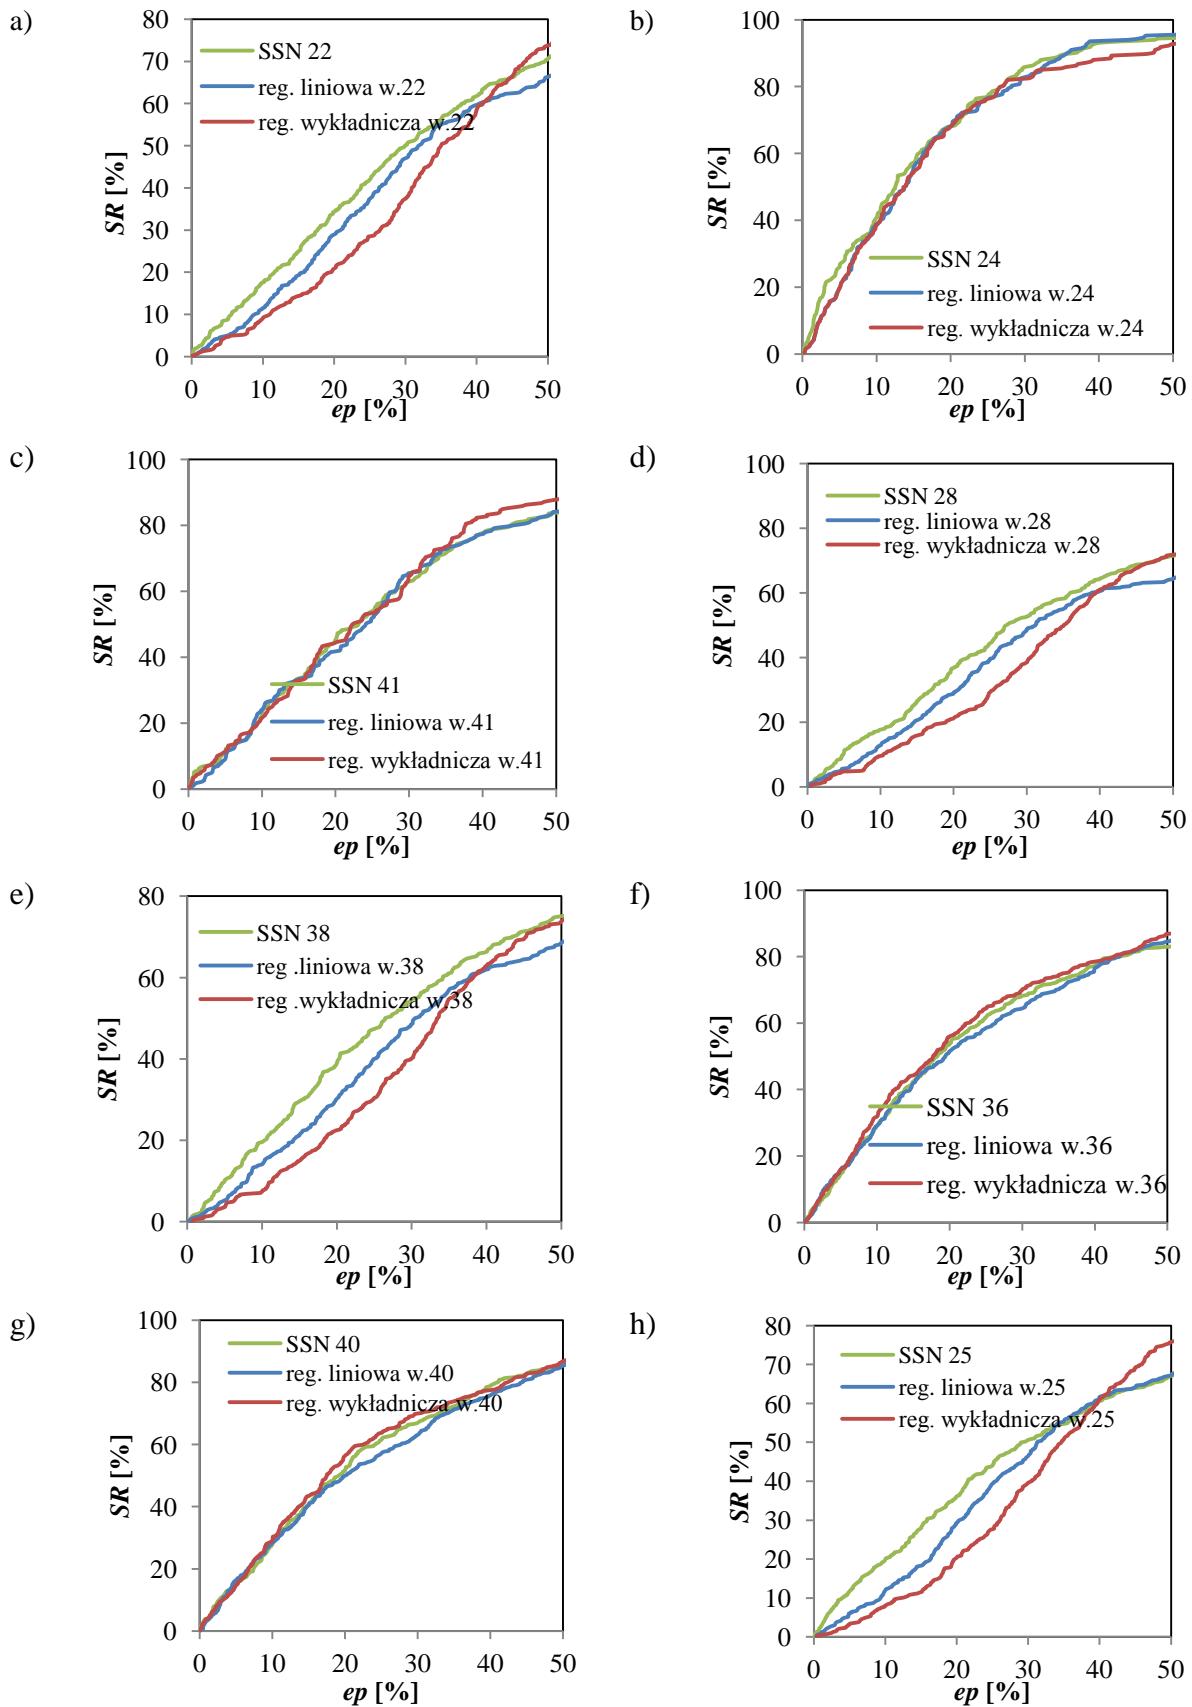
Analizując wyniki uzyskane z zastosowaniem wzorów empirycznych stwierdzono, że największy procent sukcesu  $SR$  występuje w przypadku wariantów nr 3 oraz nr 24. W wariacie 3 w informacji wejściowej podano:  $a_{ygmax}$ ,  $En$ ,  $r_e$ , natomiast w przypadku wariantu nr 24:  $v_{ygmax}$ ,  $En$ ,  $r_e$ . W obydwu tych wariantach analizowano przekazywanie się drgań w kierunku  $y$ . Można zatem stwierdzić, że kierunek  $y$  jest łatwiejszy do prognozowania za pomocą wzorów empirycznych.

Stwierdzono, że obliczenia ułamków  $r$  za pomocą wzorów empirycznych mogą być bardzo przydatne, ze względu na prostotę bez specjalistycznego oprogramowania i niewielki nakład pracy. Rezultaty są jednak gorsze niż uzyskane z użyciem sieci neuronowych. W celu poprawy dokładności, należałoby używać wzorów z dużą liczbą parametrów „wejściowych”, co oznacza pewien wysiłek (w tym też numeryczny; np. FFT) związany z przygotowaniem danych.



Rys. 5.1. Procent sukcesu  $SR$  prognozy przekazywania przyspieszeń drgań z gruntu na fundament budynku o średniej wysokości przypadku: a) wariantu nr 1, b) wariantu nr 2, c) wariantu nr 3, d) wariantu nr 19, e) wariantu nr 7, f) wariantu nr 16, g) wariantu nr 18, h) wariantu nr 4





Rys. 5.2. Procent sukcesu  $SR$  prognozy przekazywania prędkości drgań z gruntu na fundament budynku o średniej wysokości przypadku: a) wariantu nr 22, b) wariantu nr 24, c) wariantu nr 41, d) wariantu nr 28, e) wariantu nr 38, f) wariantu nr 36, g) wariantu nr 40, h) wariantu nr 25

## 6. WNIOSKI I UWAGI KOŃCOWE

Praca poświęcona jest zagadnieniom związanym z przekazywaniem drgań parasejsmicznych z gruntu na fundament ścianowego budynku mieszkalnego, typowego w klasie budynków o średniej wysokości. Źródłem tych drgań były wstrząsy górnicze, powstałe na skutek wydobycia rudy miedzi w Legnicko-Głogowskim Okręgu Miedziowym (LGOM). Analizowano obszerne wyniki badań doświadczalnych w skali naturalnej, uzyskane z pomiarów przy użyciu aparatury „czuwającej”. Badano wpływ parametrów wstrząsów górniczych (energia wstrząsu, odległość epicentralna, współrzędne sejsmologiczne) oraz parametrów wywołanych przez nie drgań gruntu obok budynku (maksymalne wartości przyspieszeń oraz prędkości drgań gruntu, a także dominujące częstotliwości drgań gruntu) na transmisję drgań (przyspieszeń i prędkości poziomych drgań składowych oraz wypadkowych) z gruntu na dolną część budynku. Następnie wyniki badań doświadczalnych wykorzystano jako podstawę do zaprojektowania sztucznych sieci neuronowych różnego typu oraz opracowania modeli regresji wielokrotnej do prognozowania przekazywania drgań gruntu pochodzenia górniczego na fundament budynku. W utworzonych modelach obliczeniowych rozważano różne warianty wprowadzanej informacji wejściowej i analizowano wpływ uwzględnienia poszczególnych parametrów wstrząsów górniczych i drgań gruntu na dokładność przewidywania tego przekazywania.

Przeprowadzone badania pozwalają na sformułowanie następujących wniosków i uwag końcowych:

1. Różnice w przebiegach drgań gruntu i fundamentu budynku odbywających się w tym samym czasie mogą być znaczące tak w przypadku przyspieszeń, jak i prędkości drgań, zarówno w zakresie drgań składowych (równoległych do osi poprzecznej oraz podłużnej budynku), jak i wypadkowych. W szczególności dotyczą one: maksymalnych wartości (amplitud) drgań, czasu wystąpienia tych wartości, dominujących częstotliwości drgań.
2. Rezultaty przeprowadzonych analiz wyników badań doświadczalnych w zakresie redukcji maksymalnych wartości składowych przyspieszeń i prędkości, a także maksymalnych wartości wypadkowych przyspieszeń i prędkości drgań wywołanych wstrząsami górniczymi przy ich przekazywaniu z gruntu na fundament budynku o średniej wysokości, wskazują na zróżnicowany sposób tego przekazywania. Można dopatrywać się wpływu parametrów wstrząsów (energii wstrząsu, odległości epicentralnych, wzajemnego położenia ogniska wstrząsu i budynku – współrzędnych sejsmologicznych wstrząsu) oraz parametrów drgań gruntu (maksymalnych amplitud przyspieszeń oraz prędkości drgań gruntu, a także dominujących częstotliwości drgań gruntu) na wielkość tej redukcji.

Niemniej jednak wyznaczenie lub przewidywanie dokładnej zależności między maksymalnymi wartościami drgań gruntu i fundamentu od tego samego wstrząsu górniczego, ze względu na pojawiające się niejednoznaczności oraz duże rozrzuty wyników, niesie wiele trudności. Praktycznie możliwa jest tylko analiza występujących trendów oraz wartości średnich w pewnych przedziałach parametrów wstrząsów górniczych i drgań gruntu obok budynku.

3. Przy przekazywaniu drgań z gruntu na budynek, redukcja maksymalnych wartości składowych oraz wypadkowych prędkości drgań jest mniejsza niż redukcja maksymalnych wartości przyspieszeń drgań w przypadku wszystkich analizowanych wstrząsów górniczych.
4. Wyniki badań doświadczalnych wskazują, że zarówno w przypadku składowych, jak i wypadkowych przyspieszeń oraz prędkości drgań, redukcja drgań przy przekazywaniu ich z podłoża na budynek jest mniejsza w przypadku większych energii. W zakresie małych energii wstrząsów obserwuje się zdecydowanie większą różnicę w przekazywaniu prędkości i przyspieszeń drgań niż przy większych energiach.
5. Ułamki  $r$  wyliczone jako średnie z przedziału, osiągają największe wartości w przypadku najmniejszych odległości epicentralnych wstrząsów ( $r_e \leq 800$  m) i przy odległościach dużych ( $r_e > 1500$  m) w przypadku przekazywania wszystkich rodzajów drgań (składowych i wypadkowych, przyspieszeń i prędkości) z gruntu na fundament budynku.
6. Wyniki badań doświadczalnych wskazują, że kierunek propagacji fali od epicentrum wstrząsu do budynku ma wyraźny wpływ na sposób przekazywania drgań z gruntu na fundament budynku. Efekt ten występuje nawet wtedy, gdy inne parametry wstrząsu ( $En$ ,  $r_e$ ) są zbliżone.
7. Redukcja maksymalnych wartości składowych oraz wypadkowych prędkości i przyspieszeń drgań fundamentu w stosunku do odpowiednich maksymalnych wartości drgań gruntu odbywających się w tym samym czasie jest wyraźnie mniejsza w przypadku drgań gruntu z większymi amplitudami.
8. Przyspieszenia drgań przekazują się lepiej z gruntu na fundament budynku w przypadku mniejszych dominujących częstotliwości drgań gruntu ( $<10$ Hz) zarówno w kierunku  $x$ , jak i w kierunku  $y$ . Analogiczny wniosek obowiązuje w odniesieniu do redukcji składowych prędkości drgań.

9. W kierunku  $x$  występuje większa redukcja drgań przy ich przekazywaniu z gruntu na fundament budynku niż w kierunku  $y$ . Praktycznie mniejszą wartość ułamka  $r$  wyznaczono w kierunku poprzecznym  $x$  w przypadku niemal wszystkich rozważanych wstrząsów zarówno w przypadku prędkości, jak i przyspieszeń drgań.
10. Trudności, jakie występują w prognozowaniu różnic w jednocześnie trwających drganiach gruntu i fundamentu budynku stały się przesłanką do wykorzystania sztucznych sieci neuronowych do tego celu. Obliczenia wykonano za pomocą standardowych sztucznych sieci neuronowych (SSN) typu wstecznej propagacji błędu (WPB) z algorytmem uczenia Levenberga – Marquardta (LM), sztucznych sieci neuronowych z regularyzacją (SSN+reg.), bayesowskich sieci neuronowych (BSN). Zaproponowano też użycie kaskadowych sieci neuronowych (KSN).
11. Wydaje się, że zaproponowane sieci neuronowe wszystkich rozważanych typów mogą być przydatne do przewidywania redukcji maksymalnych wartości składowych i wypadkowych prędkości oraz przyspieszeń drgań przy ich przekazywaniu z gruntu na budynek.
12. Użycie sieci neuronowych z regularyzacją oraz bayesowskich sieci neuronowych zamiast standardowych sieci neuronowych typu wstecznej propagacji błędu nie skutkuje istotnym zwiększeniem dokładności aproksymacji neuronowej. Osiągnięcie większych dokładności jest natomiast możliwe z wykorzystaniem sieci kaskadowych.
13. We wszystkich przypadkach neuronowego prognozowania przekazywania przyspieszeń oraz prędkości drgań z gruntu na fundament budynku, większe dokładności uzyskano w przypadku prędkości drgań przy analogicznej informacji wejściowej sieci.
14. Kierunek podłużny  $y$  jest stosunkowo dobrze „przewidywalny” za pomocą sieci neuronowych. Takie wyniki uzyskano dla wszystkich analizowanych sieci do prognozowania przekazywania składowych prędkości i przyspieszeń drgań, niezależnie od wariantu wektora wejścia. Dużo większe błędy przy wyliczaniu ułamka  $r$  pojawiają się przy próbie „łącznego” uwzględnienia obu kierunków drgań w jednej sieci neuronowej, co jest wynikiem znacznych różnic w sposobie przekazywania drgań w kierunkach  $x$  i  $y$  (a tym samym we wzorcach im odpowiadających).
15. Wydaje się, że sieci neuronowe mogą być pomocne do oceny wagi wpływu różnych parametrów wstrząsów górniczych i drgań gruntu obok budynku na przekazywanie drgań z podłoża na budynek. Przykładowo, podanie w informacji wejściowej sieci neuronowej współrzędnych sejsmologicznych ( $X$ ,  $Y$ ) wstrząsu górniczego zamiast odległości

epicentralnej  $r_e$ , może istotnie wpłynąć na zwiększenie dokładności neuronowej prognozy przekazywania drgań z gruntu na fundament budynku. Znaczące zwiększenie dokładności prognozowania ułamka  $r$  osiąga się poprzez podanie w wektorze wejścia sieci neuronowej dominującej częstotliwości drgań gruntu (prędkości lub przyspieszenia w zależności od wariantu wektora wejścia). W przypadku prognozowania ułamka  $r$  za pomocą jednej sieci łącznie w kierunku  $x$  i  $y$ , zdecydowanie lepsze wyniki uzyskuje się podając na wejściu sieci parametr opisujący (separujący) kierunki drgań  $k$ .

16. Wzory empiryczne (modele regresji liniowej i wykładniczej), w których wykorzystano te same parametry „wejściowe” co użyte w neuronowym prognozowaniu przekazywania drgań z gruntu na fundament budynku, dają wartości ułamków  $r$  mniej dokładne niż sieci neuronowe, czego można było się spodziewać. Niemniej jednak, wykonanie obliczeń ułamków  $r$  za pomocą wzorów empirycznych jest proste i nie wymaga specjalistycznego oprogramowania, stąd wynika ich przydatność. Dokładność takich obliczeń rośnie przy zwiększającej się liczbie parametrów „wejściowych”, a to oznacza już pewien wysiłek (w tym też numeryczny; np. FFT) związany z przygotowaniem danych.

Modele neuronowe i regresji wielokrotnej zaproponowane w niniejszej pracy są „modelami otwartymi”. Można je rozbudowywać dołączając nowe informacje wejściowe (np. dotyczące podłoża gruntowego, czasu trwania obciążenia). Z kolei nowe dane pomiarowe pozwolą na wzbogacanie liczby wzorców i sukcesywne aktualizowanie zaproponowanych sieci neuronowych.

## **7. PROPOZYCJE KIERUNKÓW DALSZYCH BADAŃ ZWIĄZANYCH Z TEMATEM**

We wcześniejszych rozdziałach wykazano, że za pomocą różnego typu sztucznych sieci neuronowych można prognozować przekazywanie przyspieszeń oraz prędkości drgań z gruntu na fundament pięciokondygnacyjnego budynku mieszkalnego. W zastosowanym w niniejszej pracy modelu użyto stosunkowo obszernego zbioru informacji z pomiarów dynamicznych.

Modele użyte w pracy są modelami otwartymi czyli takimi, które można poszerzyć o nowe informacje uzyskiwane podczas kolejnych, bardziej szczegółowych badań. Poszerzenie danych do uczenia, walidacji oraz testowania może iść w kierunku uwzględnienia w modelu informacji na temat rodzaju gruntu, sposobu posadowienia budowli, czasu trwania obciążenia.

Efekt redukcji drgań na styku podłoże - obiekt zależy od właściwości dynamicznych danego typu budowli. Ten wpływ nie został uwzględniony w niniejszej pracy, gdyż wszystkie badania dotyczyły budynku o średniej wysokości reprezentatywnego dla obiektów o konkretnej konstrukcji. Rozszerzenie badań o budynki niskie oraz wysokie, o różnych konstrukcjach nośnych byłoby możliwe poprzez uwzględnienie w kształtowaniu modelu również tego parametru.

W pracy zastosowano różnego typu sztuczne sieci neuronowe tj.: standardowe sztuczne sieci neuronowe, sztuczne sieci neuronowe z regularyzacją, bayesowskie sieci neuronowe oraz kaskadowe sieci neuronowe. Do kolejnych analiz proponuje się zastosowanie sztucznych sieci neuronowych z wnioskowaniem rozmytym oraz tzw. zmiennych lingwistycznych. Oddają one „niepewny” i „nieostry” charakter wielu parametrów i zjawisk występujących podczas przekazywania drgań z podłoża na budynek.

## LITERATURA

- [1] Agabein M.E., Parmelee R.A., Lee L., *A model for the study of soil-structure interaction*, Proc. Eight Congress Inter Association for Bridge and Structural Eng., New York, 1968, Final report.
- [2] Ambrosini R.D., Riera J.D., Danesi R.F., *On the influence of foundation flexibility on the seismic response of structures*, Computers & Geotechnics, 27(3), 2000, 179-197.
- [3] Amiri, G.: *Seismic Sensitivity Indicators for Tall Guyed Telecommunication Towers*, Computers and Structures, 80, p.349-364, 2002.
- [4] Aviles J., Suarez M.: *Effective periods and dampings of building-foundation systems including seismic wave effects*, Engineering Structures, 24, 2002, 553-562.
- [5] Bishop C.M., *Pattern Recognition and Machine Learning*, Springer, 2006.
- [6] Bode Ch., Hirschauer R., Savidis S. A., *Soil-structure interaction in the time domain using half space Green 's functions*, Soil Dynamics and Earthquake Engineering, 22, 2002, 283-295.
- [7] Chassiakos A.G., Masri S. F., *Identification of the internal forces of structural systems using feedforward multilayer networks*, Computing Systems in Engineering, 2, 1, 1991, 125 – 134.
- [8] Chen H.M., Tsai K.H., Qi G.Z., Yang J.C.S., Amini F., *Neural network for structural control*, Journal of Computing in Civil Engineering, 9, 2, 1995, 168-176.
- [9] Chen H.M., Qi G.Z., Yang J.C.S., Amini F., *Neural network for structural dynamic identification*, Journal of Engineering Mechanics, 121, 12, 1995, 1377-1381.
- [10] Cheng M., Popplewell N., *Neural network for earthquake selection in structural time history analysis*, Earthquake Engineering and Structural Dynamics, 23, 1994, 303-319.
- [11] Chudyba Ł., *Wykorzystanie SSN w analizie przekazywania się drgań wzbudzonych wstrząsami górniczymi z gruntu na budynek*, Zeszyty Naukowe Politechniki Śląskiej, Budownictwo, z. 113, nr 1799, 2008, 31-38.
- [12] Chudyba Ł., *Wpływ typu sieci neuronowej na dokładność prognozowania przekazywania drgań pochodzenia górniczego z gruntu na budynek – Czasopismo Techniczne 1-B/2011, Zeszyt 3, Rok 108, Kraków 2011, 3-12.*
- [13] Ciesielski R, Maciąg E., *Drgania drogowe i ich wpływ na budynki*, Wyd. Kom. i Łącz., Warszawa 1990.
- [14] Cloud W. K.: *Modification of seismic waves by a building*, 6 Europ. Earthq. Eng., Dubrovnik 1978.
- [15] Davenne L., Ragueneau F., Mazars J., Ibrahimbegovic A., *Efficient approach to finite element analysis in earthquake engineering*, Computers & Structures, 81(12), 2003, 1223-1239.



- [16] De Stefano A., Sabia D., Sabia L., *Probabilistic neural networks for seismic damage mechanisms prediction*, Earthquake Engineering and Structural Dynamics, 28, 1999, 807-821.
- [17] Dubiński J., Mutke G., Jaśkiewicz K., Lurka A., *Górnicza Skala Intensywności GSI-2004 do oceny skutków drgań wywołanych wstrząsami górnictwymi w obszarze LGOM – geneza, skala i weryfikacja*.
- [18] Dutta S.C, Bhattacharya K., Roy R., *Response of low-rise buildings under seismic ground excitation incorporating soil-structure interaction*, Soil Dynamics & Earthquake Engineering, 24(12), 2004, 893-914.
- [19] Elkordy M.F., Chang K.C., Lee G.C., *A structural damage neural network monitoring system*, Microcomputers in Civil Engineering, 9, 1994, 83-96.
- [20] Foresee F.D., Hagan M., *Gauss-Newton approximation to Bayesian learning*.
- [21] Grange S., Botrugno L., Kotronis P., *The effects of Soil-Structure Interaction on a reinforced concrete viaduct*, Earthquake Engineering and Structural Dynamics, 40(1), 2011, 93-105.
- [22] Haykin S., *Neural networks – comprehensive foundation*, Prentice Hall Intern. Inc., Upper Saddle River, New York, 2<sup>nd</sup> edition, 1999.
- [23] Huang Ch. – Ch., Loh Ch. – H., *Nonlinear identification of dynamic systems using neural networks*, Computer – Aided Civil Infrastructure Engineering, 16, 2001, 28-41.
- [24] Huang C.S., Hung S.L., Wen C.M., Tu T.T., *A neural network approach for structural identification and diagnosis of a building from seismic response data*, Earthquake Engineering and Structural Dynamics, 32, 2003, 187-206.
- [25] Humar J.L., Bagchi A., Xia H., *Frequency domain analysis of soil-structure interaction*, Computers and Structures, 66, 1998, 337-351.
- [26] Hung S.L., Kao C.Y., *Structural damage detection using the optimal weights of the approximating artificial neural networks*, Earthquake Engineering and Structural Dynamics, 31, 2002, 217-234.
- [27] Housner G.W.: *Interaction of building and ground during an earthquake*. Bull. Seism. Soc. Amer. Vol. 47, Nr 2, 1957.
- [28] Ihizaki H., Hatakyama N.: *Experimental and numerical studies on vibrations of buildings*. Proc. of the 2<sup>nd</sup> World Conf. on Earthq. Eng., Tokyo 1960.
- [29] Kanai K., Suzuki T., *Relation between the property of building vibration and the nature of ground*. (Observation of earthquake motion at actual buildings), Bull. Earthq. Res. Inst., 31, Tokyo 1953.
- [30] Kanai K., Suzuki T., *Relation between the property of building vibration and the nature of ground*. (Observation of earthquake motion at actual buildings), Bull. Earthq. Res. Inst., 1, Tokyo 1955, 108-120.



- [31] Kanai K., Tanaka T., Suzuki T., *Rocking and elastic vibrations of actual building*, II (Observation of earthquake motion), Bull. Earthq. Res. Inst., 36, Tokyo 1958, 201-226.
- [32] Kanai K., Tanaka T., Suzuki T., *Rocking and elastic vibrations of actual building*, I (Experiments by vibration generator), Bull. Earthq. Res. Inst., 36, Tokyo 1958, 183-199.
- [33] Kawecki J., *Rola badań doświadczalnych w diagnostyce dynamicznej obiektów budowlanych*, Inżynieria i Budownictwo nr 12/2005, s. 667-677.
- [34] Kawecki J., *Diagnostyka drgań komunikacyjnych na budynki i ludzi w budynkach*, Transport Miejski i Regionalny, Nr 11, 2006.
- [35] Kawecki J., Kozioł K., Stypuła K., *Wpływ konstrukcji obudowy tunelu metra na prognozowany odbiór gwałtów przez ludzi przebywających w pobliżu budynku*, Czasopismo Techniczne, 3-B/2010 Zeszyt 11, Kraków 2010, 51-58.
- [36] Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe – podstawy i zastosowanie*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [37] Kuźniar K., *Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych*, Monografia 310, Seria Inżynieria Lądowa, Politechnika Krakowska, Kraków 2004.
- [38] Kuźniar K., Chudyba Ł., *Prognozowanie interakcji dynamicznej grunt-budynek w przypadku drgań wzbudzonych wstrząsami górniczymi*, Zeszyty Naukowe Politechniki Rzeszowskiej, Mechanika, z. 74, nr 258, 2008, 181-190.
- [39] Kuźniar K., Chudyba Ł., *Wykorzystanie sieci neuronowych do prognozowania przekazywania drgań wzbudzonych wstrząsami górniczymi z gruntu na budynek*, Czasopismo Techniczne 3-B/2010, Zeszyt 11, Rok 107, Kraków 2010, 109-117.
- [40] Kuźniar K., Chudyba Ł., *Analiza wpływu kierunku propagacji drgań od wstrząsów górniczych na ich przekazywanie z gruntu na budynek*, Materiały 56 Konferencji Naukowej KILiW PAN i KN PZITB, Problemy naukowo-badawcze budownictwa, Krynica, wrzesień 2010, 185-192.
- [41] Kuźniar K., Chudyba Ł., *Neural Networks for the Analysis of Mine-Induced Vibrations Transmission from Ground to Building Foundation*, 13<sup>th</sup> International Conference, EANN 2012, London, UK, September 2012, Springer, 162-171.
- [42] Kuźniar K., Maciąg E.: *Zastosowanie SSN w wyznaczeniu wpływu wstrząsów górniczych na interakcję dynamiczną grunt-budynek*, Zeszyty Naukowe Politechniki Białostockiej, Budownictwo, z. 28, t. 2, Białystok 2006, 187-196.
- [43] Kuźniar K., Maciąg E., Tataro T.: *Acceleration response spectra from mining tremors*, First European Conference on Earthquake Engineering and seismology (ECEES), Geneva 2006, Switzerland, Abstract Book, 466-467 (full paper on CD), 2006.

- [44] Luco J.E., Trifunac M.D., Wong L., *Isolation of soil-structure interaction effects by full-scale forced vibration tests*, Earthquake Engineering and Structural Dynamics, vol. 16, 1-21 (1988).
- [45] Ma H.J., Quek S.T., Ang K.K., *Soil-structure interaction effect from blast-induced horizontal and vertical ground vibration*, Engineering Structures, 26(12), 2004, 1661-1675.
- [46] Maciąg E., *Interakcja układu budynek-podłoże podlegającego działaniom sejsmicznym i parasejsmicznym (praca przeglądowa)*, Mechanika Teoretyczna i Stosowana, 17,4,1979,497-536.
- [47] Maciąg E., *Doświadczalna ocena zmian cech dynamicznych budynków w zależności od sposobu ich posadowienia*, AIL, tom XXVII, z. 4,1981.
- [48] Maciąg E., *Experimental evaluation of changes of dynamic properties of buildings on different grounds*, Earthquake Engineering and Structural Dynamics, 14, 1986, 925-932.
- [49] Maciąg E., *Ocena szkodliwości wstrząsów górniczych dla budynków na podstawie drgań ich fundamentów czy gruntu?*, Inżynieria i Budownictwo, 12/2005.
- [50] Maciąg E.: *Interakcja układu budynek – podłoże gruntowe w świetle doświadczalnego badania drgań parasejsmicznych*, Inżynieria Morska i Geotechnika nr 4/2006., 240-250.
- [51] Maciąg E. Bobola K., Tataro T. *Ocena teoretyczna i doświadczalna cech dynamicznych i odpowiedzi na obciążenia parasejsmiczne budynków typu DOMINO i WUFT*, XXVII Konferencja naukowa, Krynica 1981.
- [52] Maciąg E., Kuźniar K., *Wpływ elementów niekonstrukcyjnych na częstotliwości drgań własnych ścianowych budynków prefabrykowanych*, Inżynieria i Budownictwo, 10, 1993,423-425.
- [53] Maciąg E., Kuźniar K.: *The influence of ground flexibility on the fundamental frequencies of natural vibrations of medium – height buildings with load bearing concrete walls*. Arch. Civ. Eng XXXIX,2, 1993.
- [54] Maciąg E., Kuźniar K.: *Wpływ parametrów wstrząsów górniczych na interakcję dynamiczną grunt-budynek*, Zeszyty Naukowe Politechniki Rzeszowskiej nr 243, 113-123, 2007.
- [55] Madugula, M.: *Dynamic Response of Lattice Towers and Guyed Masts*, ASCE, Virginia, 2002 Codes.
- [56] Masri S.F., Chassiakos A.G., Caughey T.K., *Identification of nonlinear dynamic systems using neural networks*, Journal of Applied Mechanics, 60, 1993, 123-133.
- [57] Masters T., *Sieci neuronowe w praktyce. Programowanie w języku C++*, Wydawnictwa Naukowo – Techniczne, Warszawa 1996.

- [58] Miller B., Piątkowski G., Ziemiański L., *The use of neural networks for prediction of dynamic characteristics of elastic – plastic structures*, Materiały XIII Polskiej Konf. Metod Komputerowych w Mechanice, Poznań 1997, t. 3, 893-900.
- [59] Mycielski J., *Ekonometria*, WNE UW, Warszawa 2009.
- [60] Olszewska D., *Ocena efektów lokalnych i struktury częstotliwościowej sygnałów sejsmometrycznych dla poprawy dokładności prognozy rozprzestrzeniania drgań wzbudzanych wstrząsami górnictwymi w Legnicko – Głogowskim Okręgu Miedziowym*, Praca doktorska, Kraków 2008.
- [61] Osawa Y., Tanaka, Murakami M., Kitagawa Y.: *Earthquake measurements in an around a reinforced concrete building*. Proc. of the Fourth World Conf. on Earth. Eng. Chile 1969.
- [62] Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wyd. Naukowo – Techniczne, Warszawa 1996.
- [63] Osowski S. *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [64] Pachla F., *Ocena szkodliwości wybranych wstrząsów z obszaru LGOM przez górnictwowe skale intensywności GSI-2004*, Zeszyty Naukowe. Budownictwo. Politechnika Śląska, z. 113, 2008, 243 - 250.
- [65] Pala M., Caglar N., Elmas M., Cevik A., Saribiyik M. *Dynamic soil-structure interaction analysis of buildings by neural networks*. Construction and Building Materials 22 (2008), 330-342.
- [66] Rodriguez M.E., Montes R., *Seismic response and damage analysis of buildings supported on flexible soils*, Earthquake Engineering and Structural Dynamics, 29, 2000, 647-665.
- [67] Rydlewski J. P., *Estymatory największej wiarygodności w uogólnionych modelach regresji nieliniowej*, Praca doktorska napisana pod kierunkiem dr hab. Antoniego Leona Dawidowicza prof. UJ, Kraków 2009.
- [68] Shakib H., *Evaluation of dynamic eccentricity by considering soil-structure interaction: a proposal for seismic design codes*, Soil Dynamics & Earthquake Engineering, 24(5), 2004, 369-378.
- [69] Shakib H., Fuladgar A., *Dynamic soil-structure interaction effects on the seismic response of asymmetric buildings*, Soil Dynamics & Earthquake Engineering, 24(5), 2004, 379-388.
- [70] Spyrakos C.C., Koutromanos I.A., Maniatakis C.A., *Seismic response of base-isolated buildings including soil-structure interaction*, Soil Dynamics & Earthquake Engineering, 29(4), 2009, 658-668.
- [71] Spyrakos C.C., Maniatakis C.A., Koutromanos I.A., *Soil-structure interaction effects on base-isolated buildings founded on soil stratum*, Engineering Structures, 31(3), 2009, 729-737.

- [72] Stewart J.P., Fenves G.L., *System identification or evaluating soil-structure interaction effects in buildings from strong motion recordings*, Earthquake Engineering and Structural Dynamics, 27, 1998,869-885.
- [73] Stephens J.E., Van Luchene R.D., *Integrated assessment damage in structures*, Microcomputers in Civil Engineering, 9, 1994, 119-128.
- [74] Stypuła K., *Badania propagacji w podłożu gruntowym oraz przekazywanie się na budynki drgań wywołanych wbijaniem pali fundamentowych*, praca doktorska, Biblioteka Główna Politechniki Krakowskiej, Kraków 1981.
- [75] Stypuła K. *Drgania mechaniczne wywołane eksplozją metra płytkiego i ich wpływ na budynki*, Zeszyty Naukowe Politechniki Krakowskiej, Inżynieria Lądowa nr 72, Kraków 2001.
- [76] Stypuła K., *Wybrane aspekty uwzględniania wpływu drgań kolejowych na budynki i ludzi w budynkach w przypadku inwestycji kolejowych*, Materiały Konferencji naukowo – technicznej Projektowanie, budowa i utrzymanie infrastruktury w transporcie szynowym, INFRASZYN 2011, Zakopane 2011, 211-225.
- [77] Stypuła K., Koziół K., *Problematyka drgań budynków posadowionych w sąsiedztwie linii kolejowych*, Materiały Konferencji naukowo – technicznej Projektowanie, budowa i utrzymanie infrastruktury w transporcie szynowym, INFRASZYN 2009, Zakopane 2009, 303-316.
- [78] Stypuła K., Koziół K., *Konieczność wykonywania prognoz wpływu drgań kolejowych na budynki i ludzi w budynkach przed zastosowaniem wibroizolacji w nawierzchni szynowej*, Materiały Konferencji naukowo – technicznej Projektowanie, budowa i utrzymanie infrastruktury w transporcie szynowym, INFRASZYN 2010, Zakopane 2010, 222-230.
- [79] Stypuła K., Koziół K., Stecz P. *Inwestycje transportu szynowego w Polsce a problemy ochrony środowiska przed wibracjami*, Materiały Konferencji naukowo – technicznej Projektowanie, budowa i utrzymanie infrastruktury w transporcie szynowym, Zakopane 2008, 276-291.
- [80] Sukiennik M., *Sieci neuronowe – szanse i możliwości ich wykorzystania w przemyśle wydobywczym*, Materiały Krakowskiej Konferencji Młodych Uczonych 2009, Kraków 17-19 września 2009.
- [81] Tadeusiewicz R. *Sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1993.
- [82] Tataro T. *Działanie drgań powierzchniowych wywołanych wstrząsami górniczymi na niską tradycyjną zabudowę mieszkalną*, Zeszyty Naukowe Politechniki Krakowskiej, seria: Inżynieria Lądowa nr 74, Kraków 2002.
- [83] Todorovska I. M., *Full – scale experimental studies of soil structure interaction*, ISET Journal of Earthquake Technology, Paper No. 422, Vol. 39, No. 3, September 2002, 139-165.

- [84] Trifunac D., *Full – scale experimental studies of soil structure interaction*, Izgradnja 62 12, s. 491-516, 2008.
- [85] Waszczyszyn Z., *Zastosowanie sztucznych sieci neuronowych w inżynierii lądowej*, XLI Konf. Nauk. KILiW PAN i KN PZITB, Materiały pokonferencyjne, Krynica 1995, t.9, 251-288.
- [86] Waszczyszyn Z., ed., *Neural networks in the analysis and design of structures*, CISM Courses and Lectures No. 404, Springer, Wien –New York 1999.
- [87] Waszczyszyn Z., *Bayesowskie sieci neuronowe w analizie problemów regresji*, Zeszyty Naukowe Politechniki Rzeszowskiej 258, Mechanika 74, Rzeszów-Bystre 2008.
- [88] Waszczyszyn Z., *Advances of Soft Computing in Engineering*, CISM Courses and Lectures No. 512, Springer Wien-New York 2010.
- [89] Waszczyszyn Z. Kłós. M., *Modal analysis and modified cascade neural Network In identyfikation of geometrical parameters of circular arches*, Computers and Structures 89 (2011), s. 581-589.
- [90] Waszczyszyn Z., Piątkowski G., *Identification problems of Recurrent Cascade Neural Network application in predicting an additional mass location*, Computer Assisted Mechanics and Engineering Sciences, 18, 2011, 217-228.
- [91] Waszczyszyn Z. Słoński M., *Selected problems of artificial neural networks development*. In: Waszczyszyn Z., ed., CISM Advanced School on Advances of soft Computing in engineering, pages 91. Udine, Italy, Dec. 8-12, 2007. Springer (in press), 2008.
- [92] Wolf J.P., *Foundation vibration analysis using simple physical models*, Upper Saddle River NJ USA: Prentice-Hall, 1994.
- [93] Wolf J.P., Song C., *Finite-Element Modelling of Unbounded Media*, Chichester UK: Wiley and Sons, 1996.
- [94] Wolf J.P., Song Ch., *Some cornerstones of dynamic soil-structure interaction*, *Engineering Structures*, 24, 2002, 13-28.
- [95] Wu X., Ghaboussi J., Garret J.H. Jr., *Use of neural networks in detection of structural damage*, Computers and Structures, 42, 4, 1992, 649-659.
- [96] Yun Ch.-B., Kim D.-K., Kim I-M., *Analytical frequency-dependent infinite elements for soil-structure interaction analysis in two-dimensional medium*, *Engineering Structures*, 22, 2000, 258-271.
- [97] Zhang X., Wegner IL., Haddow J.B., *Three-dimensional dynamic soilstructure interaction analysis in the time domain*, *Earthquake Engineering and Structural Dynamics*, 28, 1999, 1501-1524.

### **Inne materiały wykorzystane w pracy:**

- [98] Demuth H., Beale M., Hogan M.. *Neural Network Toolbox for use with Matlab 5, User's Guide*, 2005-2007.
- [99] Instrukcja prowadzenia powierzchniowych pomiarów sejsmicznych, interpretacji wyników oraz oceny i prognozowania drgań sejsmicznych wywołanych wstrząsami górnictwymi na powierzchni LGOM w oparciu o skalę GSI – 2004, 2004.
- [100] Neural Network Toolbox for Use with Matlab. User's Guide. Version 3.0. The Math-Works, Inc. 2006.



## SPIS RYSUNKÓW

- Rys. 2.1. Rzut poziomy i przekrój pionowy budynku
- Rys. 2.2. Schematyczna mapa lokalizacji analizowanych wstrząsów górniczych i budynku
- Rys. 2.3. Profil geologiczny otworów wiertniczych w sąsiedztwie analizowanego budynku do głębokości 90 m: a) otwór nr 1 (500m), b) otwór nr 2 (800m), c) otwór nr 3 (1000m), d) otwór nr 4 (1200m), e) położenie otworów względem analizowanego budynku [60]
- Rys. 2.4. Gęstość prawdopodobieństwa rozkładu normalnego energii rozważanych wstrząsów górniczych w LGOM
- Rys. 2.5. Gęstość prawdopodobieństwa rozkładu normalnego odległości epicentralnych rozważanych wstrząsów górniczych w LGOM
- Rys. 2.6. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $E_n = 4,1E7 \text{ J}$  i  $r_e = 1567 \text{ m}$
- Rys. 2.7. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w kierunku  $y$  w przypadku wstrząsu górniczego  $E_n = 3,9E6 \text{ J}$  i  $r_e = 580 \text{ m}$
- Rys. 2.8. Przebieg prędkości drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $E_n = 9,5E6 \text{ J}$  i  $r_e = 698 \text{ m}$
- Rys. 2.9. Przebieg prędkości drgań na gruncie oraz fundamencie w kierunku  $x$  w przypadku wstrząsu górniczego  $E_n = 1,9E7 \text{ J}$  i  $r_e = 3562 \text{ m}$
- Rys. 2.10. Trajektorie końca wypadkowego wektora przyspieszeń drgań (a) oraz prędkości drgań (b) jednocześnie występujących na gruncie i na fundamencie rozważanego budynku w przypadku wstrząsu górniczego:  $E_n=1.2E7\text{J}$ ,  $r_e=698\text{m}$  [39]
- Rys. 2.11. Przebieg wypadkowych przyspieszeń drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $E_n = 2,6E7 \text{ J}$  i  $r_e = 1540 \text{ m}$
- Rys. 2.12. Przebieg wypadkowych prędkości drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $E_n = 8,3E6 \text{ J}$  i  $r_e = 1569 \text{ m}$
- Rys. 2.13. Przebieg przyspieszeń drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $E_n = 8,3E7 \text{ J}$  i  $r_e = 3180 \text{ m}$ : a) składowa w kierunku  $x$ , b) składowa w kierunku  $y$ , c) wypadkowa
- Rys. 2.14. Przebieg prędkości drgań na gruncie oraz fundamencie w przypadku wstrząsu górniczego  $E_n = 1,6E8 \text{ J}$  i  $r_e = 2090 \text{ m}$ : a) składowa w kierunku  $x$ , b) składowa w kierunku  $y$ , c) wypadkowa
- Rys. 2.15. Widmo amplitudowe przyspieszeń drgań gruntu w przypadku wstrząsu górniczego  $E_n = 6,4 \text{ E7 J}$  i  $r_e = 629 \text{ m}$  w kierunku  $x$

- Rys. 2.16. Widmo amplitudowe przyspieszeń drgań gruntu w przypadku wstrząsu górniczego  $En = 4,7E6$  J i  $r_e = 508$  m w kierunku y
- Rys. 2.17. Dominujące częstotliwości przyspieszeń drgań w przypadku wstrząsu górniczego  $En = 7,1E7$  J i  $r_e = 1724$  m w kierunku x
- Rys. 2.18. Dominujące częstotliwości przyspieszeń drgań w przypadku wstrząsu górniczego  $En = 7,1E7$  J i  $r_e = 1724$  m w kierunku y
- Rys. 2.19. Przebiegi przyspieszeń drgań w kierunku y w przypadku wstrząsu górniczego: a)  $En = 1.2E6$  J,  $r_e = 1172$  m, b)  $En = 1.2E6$  J,  $r_e = 1178$  m; c) położenie epicentrum wstrząsów (a) i (b) w stosunku do położenia budynku
- Rys. 2.20. Porównanie ułamków  $r_{axy}$ ,  $r_{vxy}$  w zależności od energii wstrząsów górniczych  $En$
- Rys. 2.21. Porównanie ułamków  $r_{WA}$ ,  $r_{WV}$  w zależności od energii wstrząsów górniczych  $En$
- Rys. 2.22. Zależność ułamka  $r_a$  od energii wstrząsów górniczych  $En$
- Rys. 2.22. Zależność ułamka  $r_v$  od energii wstrząsów górniczych  $En$
- Rys. 2.24. Porównanie ułamków  $r_{axy}$ ,  $r_{vxy}$  w zależności od odległości epicentralnej  $r_e$
- Rys. 2.25. Porównanie ułamków  $r_{WA}$ ,  $r_{WV}$  w zależności od odległości epicentralnej  $r_e$
- Rys. 2.26. Zależność ułamka  $r_a$  od odległości epicentralnej  $r_e$
- Rys. 2.27. Zależność ułamka  $r_v$  od odległości epicentralnej  $r_e$
- Rys. 2.28. Zależność ułamka  $r_{WA}$  (a) i  $r_{WV}$  (b) od współrzędnych sejsmologicznych X i Y analizowanych wstrząsów górniczych [40]
- Rys. 2.29. Zależność ułamka  $r_a$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów
- Rys. 2.30. Zależność ułamka  $r_v$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów
- Rys. 2.31. Zależność ułamka  $r_{WA}$  i  $r_{WV}$  od współrzędnej sejsmologicznej X (a) i Y (b) wstrząsów
- Rys. 2.32. Średnie wartości ułamków  $r$  w „pasmach” współrzędnej sejsmologicznej X (a, c) oraz Y (b, d) w przypadku prędkości drgań oraz przyspieszeń drgań
- Rys. 2.33. Zależność ułamka  $r_a$  od maksymalnego przyspieszenia drgań gruntu  $a_{gmax}$
- Rys. 2.34. Zależność  $r_{WA}$  od maksymalnej wartości wypadkowego przyspieszenia drgań gruntu  $PGA$
- Rys. 2.35. Zależność ułamka  $r_v$  od maksymalnej prędkości drgań gruntu  $v_{gmax}$
- Rys. 2.36. Zależność  $r_{WV}$  od maksymalnej wartości wypadkowej prędkości drgań gruntu  $PGV$
- Rys. 2.37. Zależność ułamka  $r_a$  od dominujących częstotliwości na gruncie  $f_{1ga}$
- Rys. 2.38. Zależność ułamka  $r_v$  od dominujących częstotliwości na gruncie  $f_{1gv}$
- Rys. 2.39. Gęstość prawdopodobieństwa rozkładu normalnego wartości ułamka  $r_a$  w przypadku składowych oraz wypadkowych przyspieszeń drgań



- Rys. 2.40. Gęstość prawdopodobieństwa rozkładu normalnego wartości ułamków  $r_{WA}$  i  $r_{WV}$
- Rys. 2.41. Porównanie wartości ułamków  $r_a$  (a) oraz  $r_v$  (b) w kolejnych pomiarach w zależności od kierunku drgań
- Rys. 3.1. Model sztucznego neuronu [85]
- Rys. 3.2. Sigmoidalna unipolarna (logistyczna) funkcja aktywacji  $F(u_i)$  [85]
- Rys. 3.3. Schemat propagacji sygnałów i błędów w sieci typu WPB [85]
- Rys. 3.4. Schemat działania zaproponowanej kaskadowej sztucznej sieci neuronowej
- Rys. 4.1. Zależność błędu  $MSE$  od liczby neuronów w warstwie ukrytej dla SSN 22
- Rys. 4.2. Zależność błędu  $MSE$  od liczby epok uczenia przy 8 neuronach w warstwie ukrytej dla SSN 23
- Rys. 4.3. Zależność błędu  $MSE$  od liczby neuronów w warstwie ukrytej dla SSN 19 (40 epok uczenia)
- Rys. 4.4. Zależność błędu  $MSE$  od liczby epok uczenia dla sieci o 3 neuronach w warstwie ukrytej sieci neuronowej SSN 19
- Rys. 4.5. Zależność błędu  $MSE$  od współczynnika regularyzacji  $\gamma$  w przypadku sieci o wektorze wejścia  $x_{wa(3 \times 1)} = \{PGA, En, r_e\}$ , architekturze 3-40-1 i 10 epokach uczenia
- Rys. 4.6. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań składowych z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze uczącym: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.7. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze walidującym: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.8. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku prognozowania ułamka  $r_{axy}$  w zbiorze testującym: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.9. Histogramy błędu bezwzględnego  $Ep$ : a) SSN 11 b) SSN 15, c) SSN 17
- Rys. 4.10. Wartość ułamka  $r_{axy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 11, b) SSN 15, c) SSN 17
- Rys. 4.11. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek – uczenie, testowanie – w przypadku sieci do prognozowania ułamka  $r_a$  z wektorem wejścia: a)  $x_{a(3 \times 1)} = \{a_{gmax}, En, r_e\}$ , b)  $x_{a(4 \times 1)} = \{a_{gmax}, En, X, Y\}$ , c)  $x_{a(5 \times 1)} = \{a_{gmax}, En, r_e, X, Y\}$
- Rys. 4.12. Wartość ułamka  $r_{ay}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 3, b) SSN 6, c) SSN 14
- Rys. 4.13. Procent sukcesu  $SR$  neuronowej prognozy przekazywania przyspieszeń drgań z gruntu na budynek w przypadku sieci SSN 19, SSN 20, SSN 21 : a) uczenie, b) walidacja, b) testowanie

- Rys. 4.14. Histogramy błędu bezwzględego  $Ep$  SSN 19: a) uczenie, b) walidacja, c) testowanie
- Rys. 4.15. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 19, b) SSN 20, c) SSN 21
- Rys. 4.16. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku uczenia: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.17. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku walidacji: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.18. Procent sukcesu  $SR$  neuronowej prognozy ułamka  $r_{vxy}$  w przypadku testowania: a) bez parametru  $k$ , b) z parametrem  $k$
- Rys. 4.19. Histogramy błędu bezwzględego  $Ep$  SSN 37: a) uczenie, b) walidacja, c) testowanie
- Rys. 4.20. Wartość ułamka  $r_{vxy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 32, b) SSN 37
- Rys. 4.21. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku uczenia: a)  $r_{vx}$  oraz b)  $r_{vy}$
- Rys. 4.22. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku walidacji: a)  $r_{vx}$  oraz b)  $r_{vy}$
- Rys. 4.23. Procent sukcesu  $SR$  neuronowej prognozy przekazywania prędkości drgań z gruntu na budynek w przypadku testowania: a)  $r_{vx}$  oraz b)  $r_{vy}$
- Rys. 4.24. Wartość ułamka  $r_{vy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą sieci: a) SSN 35, b) SSN 39
- Rys. 4.25. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku uczenia
- Rys. 4.26. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku walidacji
- Rys. 4.27. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na budynek w przypadku testowania
- Rys. 4.28. Wartość ułamka  $r_{wv}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 41, b) SSN 42, c) SSN 43
- Rys. 4.29. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczeń za pomocą: a) sieci 3-40-1, 10 epok uczenia z regularyzacją,  $MSE(L) = 0,0210$ ;  $MSE(V) = 0,0256$ ;  $MSE(T) = 0,027$ ; b) SSN o strukturze 3-3-1, 40 epok uczenia  $MSE(L) = 0,0222$ ;  $MSE(V) = 0,0241$ ;  $MSE(T) = 0,0266$
- Rys. 4.30. Procent sukcesu  $SR$  neuronowej prognozy (SSN i SSN + reg.) przekazywania wypadkowych przyspieszeń drgań z gruntu na budynek w przypadku: a) uczenia, b) walidacji, c) testowania

- Rys. 4.31. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych przyspieszeń drgań z gruntu na budynek w przypadku wykorzystania SSN 19 oraz BSN 19: a) uczenie, b) walidacja, c) testowanie
- Rys. 4.32. Wartość ułamka  $r_{WA}$  wyznaczona na podstawie pomiarów i obliczeń za pomocą sieci BSN 19, 3-46-1, 80 epok uczenia
- Rys. 4.33. Procent sukcesu  $SR$  neuronowej prognozy przekazywania składowych prędkości drgań z gruntu na budynek w przypadku: a) uczenia, b) walidacji, c) testowania
- Rys. 4.34. Wartość ułamka  $r_{vxy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą: a) SSN 19, b) BSN 19
- Rys. 4.35. Procent sukcesu  $SR$  neuronowej prognozy przekazywania składowych prędkości drgań z użyciem sieci kaskadowej dla: a) uczenia, b) walidacji, c) testowania
- Rys. 4.36. Wartość ułamka  $r_{vxy}$  wyznaczona na podstawie pomiarów i obliczona za pomocą kaskadowej sieci neuronowej: a) krok nr 1, b) krok nr 10
- Rys. 4.37. Procent sukcesu  $SR$  neuronowej prognozy przekazywania wypadkowych prędkości drgań z gruntu na fundament budynku w przypadku kaskadowych sieci dla: a) uczenia, c) testowania
- Rys. 4.38. Wartość ułamka  $r_{wv}$  wyznaczona na podstawie pomiarów i obliczona za pomocą kaskadowej sieci neuronowej: a) krok nr 1, b) krok nr 12
- Rys. 4.39 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 13 oraz SSN 16 do prognozowania składowych prędkości oraz przyspieszeń drgań w kierunku  $x$  dla: a) uczenia, b) walidacji c) testowania
- Rys. 4.40 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 6 oraz SSN 39 do prognozowania składowych prędkości oraz przyspieszeń drgań w kierunku  $y$  dla: a) uczenia, b) walidacji c) testowania
- Rys. 4.41 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku z użyciem SSN 7 oraz SSN 40 do prognozowania składowych prędkości oraz przyspieszeń drgań łącznie w kierunku  $x$  i  $y$  dla: a) uczenia, b) walidacji c) testowania
- Rys. 4.42 Procent sukcesu  $SR$  prognozy przekazywania drgań z gruntu na fundament budynku w przypadku SSN 20 oraz SSN 43 do prognozowania wypadkowych prędkości oraz przyspieszeń drgań dla: a) uczenia, b) walidacji c) testowania
- Rys. 5.1. Procent sukcesu  $SR$  prognozy przekazywania przyspieszeń drgań z gruntu na fundament budynku o średniej wysokości przypadku: a) wariantu nr 1, b) wariantu nr 2, c) wariantu nr 3, d) wariantu nr 19, e) wariantu nr 7, f) wariantu nr 16, g) wariantu nr 18, h) wariantu nr 4

Rys. 5.2. Procent sukcesu *SR* prognozy przekazywania prędkości drgań z gruntu na fundament budynku o średniej wysokości przypadku: a) wariantu nr 22, b) wariantu nr 24, c) wariantu nr 41, d) wariantu nr 28, e) wariantu nr 38, f) wariantu nr 36, g) wariantu nr 40, h) wariantu nr 25

## SPIS TABEL

Tabela 2.1	Liczba rozważanych wstrząsów w zależności od współrzędnej sejsmologicznej X
Tabela 2.2	Liczba rozważanych wstrząsów w zależności od współrzędnej sejsmologicznej Y
Tabela 2.3	Liczba zarejestrowanych wstrząsów w zależności od energii wstrząsu $E_n$
Tabela 2.4	Liczba zarejestrowanych wstrząsów w zależności od odległości epicentralnej $r_e$
Tabela 2.5	Zależność średnich wartości ułamków $r$ od energii wstrząsów górniczych $E_n$
Tabela 2.6	Zależność średnich wartości ułamków $r$ od odległości epicentralnych $r_e$
Tabela 2.7	Zależność średnich wartości ułamków $r$ od współrzędnej sejsmologicznej X wstrząsów
Tabela 2.8	Zależność średnich wartości ułamków $r$ od współrzędnej sejsmologicznej Y wstrząsów
Tabela 2.9	Zależność średnich wartości ułamków $r_a$ od maksymalnych przyspieszeń drgań gruntu $a_{gmax}$
Tabela 2.10	Zależność wartości średniej $r_{WA}$ od maksymalnych wypadkowych przyspieszeń drgań gruntu $PGA$
Tabela 4.1	Analizowane warianty zestawień: wektor wejścia – wektor wyjścia
Tabela 4.2	Liczba wzorców, architektura i błędy $MSE$ zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania składowych przyspieszeń drgań
Tabela 4.3	Liczba wzorców, architektura i błędy $MSE$ zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania wypadkowych przyspieszeń drgań
Tabela 4.4	Liczba wzorców, architektura i błędy $MSE$ zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania składowych prędkości drgań
Tabela 4.5	Liczba wzorców, architektura i błędy $MSE$ zaproponowanych standardowych sztucznych sieci neuronowych typu wstecznej propagacji błędu do prognozowania przekazywania wypadkowych prędkości drgań
Tabela 5.1	Wzory empiryczne z zastosowaniem regresji liniowej
Tabela 5.2	Wzory empiryczne z zastosowanie regresji wykładniczej
Tabela 5.3	Błędy $MSE$ poszczególnych wzorów empirycznych