

ZASTOSOWANIE SIECI NEURONOWYCH DO DETEKCJI IMPULSÓW
O ZNANYM KSZTAŁCIE W OBECNOŚCI SILNEGO SZUMU I TRENDU
APPLICATION OF NEURAL NETWORKS FOR DETECTION OF PULSES
OF KNOWN SHAPE IN THE PRESENCE OF STRONG NOISE AND TREND

Szymon Betka¹; Marek Blok²

¹ Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki, Gdańsk, szymonbetk@gmail.com

² Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki, Gdańsk, marek.blok@pg.edu.pl

Streszczenie: Detekcja impulsów w odebranych sygnale radiowym, zwłaszcza w obecności silnego szumu oraz trendu, jest trudnym zadaniem. Artykuł przedstawia propozycje rozwiązań wykorzystujących sieci neuronowe do detekcji impulsów o znanym kształcie w obecności silnego szumu i trendu. Na potrzeby realizacji tego zadania zaproponowano dwie architektury. W pracy przedstawiono wyniki badań wpływu kształtu impulsu, mocy zakłóceń szumowych oraz trendu obecnego w sygnałach wejściowych sieci, na skuteczność detekcji zaproponowanych rozwiązań.

Abstract: Detecting pulses in a received radio signal, especially in the presence of strong noise and trend, is a difficult task. The article presents proposed solutions based on neural networks for the detection of pulses of known shape in the presence of strong noise and trend. Two architectures are proposed for the purpose. The paper presents the results of the study of the influence of the pulse shape, the noise power, and the trend present in the input signals of the network on the detection performance of the proposed solutions.

Słowa kluczowe: detekcja impulsu, detekcja pozycji impulsu, silny szum i trend, sieć neuronowa.

Keywords: pulse detection, pulse position detection, high noise and trend, neural network.

1. WSTĘP

Detekcja sygnałów impulsowych w środowisku szumowym jest bardzo ważnym zagadnieniem w dziedzinach komunikacji bezprzewodowej, monitoringu morskiego, a także bioinformatyki [8], w których zakłócenia powodują znaczący spadek stosunku mocy sygnału do mocy szumu, co istotnie utrudnia lub uniemożliwia ich detekcję. W związku z istotą problemu, na przestrzeni lat powstało bardzo wiele klasycznych rozwiązań tego problemu: metody oparte na: filtracji [2], detekcji statystycznej [4], maszynie wektorów nośnych [6], a także metody oparte na regresji liniowej.

Wśród rozwiązań już istniejących nie zabrakło również takich opierających się na sieciach neuronowych i uczeniu maszynowym. W rozwiązaniach [3,5] zastosowano CNN w połączeniu z siecią LSTM oraz sieć *deep belief network* (DBF). W [7] użyto spłotową sieć neuronową w celu klasyfikacji sygnałów z kodowaniem Morsa. Wymienione rozwiązania osiągały znakomite wyniki, lecz ich głównym zadaniem było wykrywanie obecności sygnałów w szumie bez uwzględniania problemu estymacji parametrów sygnałów wejściowych.

W pracy zaproponowano dwa rozwiązania realizujące detekcję impulsów o znanym kształcie w obecności silnego szumu i trendu. Pierwsze rozwiązanie realizuje detekcję bazującą na wskazywaniu obecności impulsu w sygnale wejściowym, a drugie skupia się na detekcji łączącej się z estymacją podstawowych parametrów wykrywanych impulsów. W tym zakresie zaproponowano rozwiązanie wykorzystujące sieć neuronową do oszacowania początku, końca i maksymalnej amplitudy impulsu o znanym kształcie w sygnale zawierającym mocny szum i trend.

Opracowane modele sieci neuronowych przetestowano pod kątem wpływu kształtu impulsu, mocy zakłóceń szumowych oraz trendu obecnego w sygnałach wejściowych na skuteczność ich działania [1].

2. OPIS ZAPROPONOWANYCH SIECI

2.1. Architektury sieci

Do detekcji impulsów w obecności szumu i trendu opracowano sieć, której strukturę przedstawia rys. 1. Złożona jest ona z 3 warstw typu Linear. Dla pierwszych z nich zastosowano funkcje aktywacji ReLU, a dla ostatniej Sigmoid.




Rys. 1. Architektura sieci klasyfikującej sygnały

Zaproponowana sieć realizuje klasyfikację sygnału, w oparciu o podawane na wejście fragmenty sygnału o długości 500 próbek. Na jej wyjściu otrzymujemy wynik w przedziale $<0, 1>$, gdzie wartość 0 oznacza pewność, że impuls w sygnale nie występuje, a wartość 1 oznacza pewność sieci, że impuls w sygnale się znajduje.

Strukturę drugiego wariantu sieci neuronowej, służącej do detekcji położenia impulsów w obecności szumu i trendu przedstawiono na rys. 2. Sieć ta złożona jest z 3

warstw typu Linear, dla których użyto kolejno funkcji aktywacji Sigmoid, Tanh, oraz ReLU.



Rys. 2. Architektura sieci szacującej parametry impulsów

Ten wariant sieci również przetwarza sygnały wejściowe o długości 500 próbek, ale na jej wyjściu otrzymujemy trzy parametry liczbowe. Są to kolejno predykcje sieci dotyczące położenia początku impulsu, końca impulsu oraz wartości szczytowej amplitudy impulsu.

W przypadku przetwarzania przez sieć sygnału niezawierającego szukanego impulsu, wystarczającym wskaźnikiem braku impulsu w przetwarzanym sygnale jest wynik, w którym oszacowana wartość szczytowej amplitudy impulsu jest równa zero, zgodnie z logiką, z którą impuls o zerowej amplitudzie odpowiada jego brakowi.

2.2. Trening sieci

Trening zaproponowanych wariantów sieci zrealizowano z wykorzystaniem uczenia nadzorowanego. Zrealizowano go w oparciu o syntetyczne sygnały treningowe wygenerowane wraz z etykietami za pomocą narzędzi opracowanych w [1]. W zależności od badanego czynnika, generowano sygnały wraz z etykietami, zawierające impuls prostokątny lub gaussowski, zawierające trend lub nie oraz zanieczyszczone szumem białym o zadanej mocy. Szczegóły użytych sygnałów dla konkretnego modelu zostały podane przy omówieniu odpowiednich wyników testowania w kolejnych punktach.

W trakcie treningu wariantu pierwszego sieci jako kryterium uczenia zastosowano binarną entropię krzyżową, stanowiącą typową i wydajną funkcję strat dla klasyfikacji binarnej. W drugim wariantcie zastosowano kryterium L1Loss. Dla obu opisywanych sieci użyto optymalizatora Adam z współczynnikiem uczenia równym 0,001, czyli standardową wartością.

2.3. Metoda testowania sieci

Efekty działania treningu wypracowanych modeli sieci zostały zweryfikowane na wygenerowanym zbiorze syntetycznych sygnałów testowych i ich etykiet. Do oceny jakości pierwszego wariantu sieci, czyli klasyfikatora binarnego, zastosowano znane miary jakości stosowane w przypadku oceny tego typu klasyfikatorów.

W przypadku drugiego wariantu, do oceny jakości detekcji parametrów impulsu wytrenowanych modeli w procesie walidacji, od każdej wartości w wektorze wynikowym odjęto odpowiadającą jej wartość z wektora wartości oczekiwanych, otrzymując w ten sposób wektor różnic wyników i etykiet. Następnie dla każdej wartości obliczano średnie odchylenie bezwzględne, otrzymując

średni błąd estymacji początku, końca i wartości szczytowej amplitudy impulsu. Wyniki otrzymane opisaną metodą omówiono szczegółowo w kolejnych punktach.

Wytrenowane modele sieci neuronowych zostały również zweryfikowane metodą k-krotnej walidacji krzyżowej w celu ewaluacji poprawności procesu uczenia się sieci.

3. WYNIKI WARIANTU 1

3.1. Model wytrenowany za pomocą impulsów prostokątnych w obecności szumu

W celu weryfikacji skuteczności detekcji, sieć w wariantcie pierwszym wytrenowano za pomocą wygenerowanych impulsów prostokątnych, zawartych w sygnałach o długości 500 próbek, o losowej wartości amplitudy z przedziału $\langle 1, 10 \rangle$. Do sygnałów dodawany był szum o mocy 10, 15 i 20 dB. Ilość danych pozytywnych (zawierających impuls) i negatywnych (niezawierających impulsu) była jednakowa.

Wynik testowania wytrenowanych modeli za pomocą danych zawierających sygnały o takich samych zakresach wartości amplitudy jak dane testowe, lecz inną wartość mocy szumu, przedstawiono w tab. 1. Wartość precyzji wynosiła w większości przypadków walidacyjnych ponad 90%. Wyjątkiem była sytuacja, gdy moc szumu w sygnałach walidacyjnych była znacznie większa niż wartości mocy szumu w danych treningowych.

Tab. 1. Jakość detekcji impulsów prostokątnych dla różnych mocy szumu w sygnałach testowych

Moc szumu danych treningowych [dB]	Moc szumu danych testowych [dB]	Dokładność	Czułość	Precyzja	NPV
10	-5	0,86	0,99	0,78	0,99
	0	0,96	0,99	0,92	0,99
	5	0,97	0,97	0,98	0,97
	10	0,82	0,65	0,99	0,74
	20	0,51	0,214	0,93	0,52
15	-5	0,5	1	0,5	1
	0	0,64	0,99	0,58	0,99
	5	0,84	0,99	0,76	0,99
	10	0,92	0,93	0,91	0,93
	20	0,53	0,83	0,92	0,51
20	-5	0,5	1	0,5	0
	0	0,5	1	0,5	0
	5	0,61	0,99	0,56	0,99
	10	0,81	0,98	0,73	0,98
	20	0,6	0,23	0,9	0,55

Dokładność dla wszystkich modeli była najlepsza dla mocy szumu danych testowych równej lub o 5-10 dB niższej od mocy szumu w danych treningowych. Wraz ze zwiększaniem poziomu mocy szumu danych testowych sieć miała tendencję do klasyfikacji szumu w sygnałach negatywnych do kategorii pozytywnej. Wyniki dokładności i NPV na poziomie niemalże 50% odpowiadają sytuacji, gdy prawie wszystkie sygnały pozytywne zostały zakwalifikowane fałszywie.

3.2. Model wytrenowany za pomocą impulsów gaussowskich w obecności szumu

Do weryfikacji efektywności sieci w wariantcie 1 dla impulsów gaussowskim użyto sygnałów zawierających impulsy gaussowskie o wartościach szczytowych amplitudy z przedziału $\langle 1, 10 \rangle$, losowych wartościach wariancji z przedział $\langle 0,05, 0,15 \rangle$. Do generowanych sygnałów dodawano szum o mocy 5, 10 lub 30 dB. Stosunek ilości danych zawierających impuls do niezawierających był równy jeden.

Walidację skuteczności sieci przeprowadzono w dokładnie taki sam sposób jak w przypadku modelu dla impulsów prostokątnych, z tą różnicą, że zastosowano impulsy gaussowskie o takich samych parametrach jak w danych treningowych. Wyniki testowania sieci dla poszczególnych mocy szumów przedstawiono w tab. 2.

Tab. 2. Jakość detekcji impulsów gaussowskich dla różnych mocy szumu w sygnałach testowych

Moc szumu danych treningowych [dB]	Moc szumu danych testowych [dB]	Dokładność	Czułość	Precyzja	NPV
5	-10	0,8	0,99	0,72	0,99
	0	0,98	0,98	0,98	0,97
	5	0,96	0,94	0,98	0,94
	10	0,9	0,84	0,95	0,86
	20	0,67	0,49	0,76	0,62
	30	0,54	0,33	0,58	0,53
10	-10	0,5	1	0,5	1
	0	0,94	0,98	0,9	0,98
	10	0,91	0,86	0,96	0,87
	20	0,68	0,57	0,74	0,65
	30	0,54	0,61	0,53	0,54
	50	0,5	0,77	0,5	0,5
30	-10	0,5	1	0,5	0
	0	0,5	1	0,5	0
	10	0,5	1	0,5	1
	20	0,6	0,83	0,57	0,69
	30	0,53	0,52	0,53	0,54
	50	0,5	0,67	0,5	0,5

Z poszczególnych wskaźników można wywnioskować, że sieć wyuczona danymi zaszumionymi szumem o danej mocy, radzi sobie równie dobrze z wykrywaniem impulsów w sygnałach słabiej zaszumionych. Wyniki wskaźników dla mocy szumu większej niż wartość treningowa, wskazywały, że sieć większość sygnałów kwalifikuje jako negatywne, zmniejszając przez to wskaźniki NPV i precyzję. Wartości NPV równe 0 widoczne w tabeli wskazują, że sieć zakwalifikowała wszystkie sygnały do kategorii pozytywnej, przez co ilość danych TN również wyniosła 0.

3.3. Model wytrenowany za pomocą impulsów w obecności szumu i trendu liniowego

W celu sprawdzenia wpływu trendu liniowego na skuteczność detekcji sieci w wariancie pierwszym, wytrenowano i przetestowano sieć za pomocą danych o takim samym charakterze jak w p. 3.2, lecz z dodanym trendem liniowym.

Tab. 3. Wyniki testowania sieci wytrenowanej za pomocą impulsów gaussowskich w obecności szumu i trendu

Moc szumu danych treningowych [dB]	Moc szumu danych testowych [dB]	Dokładność	Czułość	Precyzja	NPV
5	-5	0,93	0,86	0,99	0,88
	0	0,92	0,85	0,99	0,87
	5	0,9	0,85	0,95	0,86
	10	0,81	0,84	0,8	0,83
	15	0,69	0,8	0,65	0,74
	-5	0,87	0,75	1	0,8
10	0	0,87	0,75	0,99	0,8
	5	0,87	0,76	0,99	0,8
	10	0,84	0,77	0,9	0,8
	15	0,7	0,81	0,66	0,76
	20	0,55	0,87	0,53	0,66
	-5	0,81	0,63	1	0,73
15	0	0,81	0,63	1	0,73
	5	0,82	0,65	0,99	0,74
	10	0,81	0,65	0,96	0,74
	15	0,73	0,68	0,76	0,71
	20	0,6	0,78	0,58	0,65

Wyniki testowania sieci w zależności od mocy szumu w danych testowych przedstawiono w tab. 3. Dodanie trendu do sygnałów sprawiło, że dokładność predykcji dla danych walidacyjnych o tej samej lub mniejszej mocy szumu niż dla danych treningowych zmniejszyła się o około 0,07, lecz dla wartości mocy szumu większych

było odwrotnie i była ona większa. Wartość precyzji dla mocy szumu takiej samej lub mniejszej jak w danych treningowych była zbliżona. Była ona jednak dużo niższa dla większej mocy szumu. Wskazania wskaźnika NPV były wyższe, a wskaźnika czułości niższe.

Dodanie trendu liniowego do danych pogorszyło jakość predykcji wytrenowanych modeli. Sieć osiągała nieco gorszą jakość predykcji niż dla sygnałów bez trendu liniowego, przy tych samych wartościach mocy szumu.

4. WYNIKI WARIANTU 2

4.1. Model wytrenowany za pomocą impulsów prostokątnych

W celu weryfikacji skuteczności detekcji sieci w wariancie drugim, sieć wytrenowano za pomocą wygenerowanych impulsów prostokątnych, o takich samych parametrach jak w p. 3.1, z tą różnicą, że moc szumu była wartością losową z przedziału $\langle 0, 30 \rangle$ dB, użyto również impulsów niezawierających szumu.

Zastosowanie do treningu sygnałów niezanieczyszczonych szumem pozwoliło na zwiększenie precyzji sieci dla sygnałów zanieczyszczonych szumem z dolnej wartości przedziału mocy.

Wyniki testowania w zależności od mocy szumu danych testowych przedstawiono w tab. 4. Charakter danych testowych był taki sam jak treningowych z tą różnicą, że moc szumu dla poszczególnych modeli sieci była stała i przyjmowała wartości od -5 do 25 dB z krokiem 5 dB.

Tab. 4. Wyniki walidacji drugiej sieci wytrenowanej za pomocą impulsów prostokątnych

moc szumu [dB]	-5	0	5	10	15	20	25
średnia bł. początku	0	0	-1	-3	-8	-20	-40
odch. st. bł. początku	7,36	10,33	15,26	26,41	42,06	61,25	80,9
średnia bł. końca	-1	-1	-2	-4	-15	-44	-102
odch. st. bł. końca	7,66	10,77	17,23	34,14	67,27	113,85	157,36
średnia bł. amplitudy	1,33	1,33	1,23	1,18	0,79	0,03	-1,29
odch. st. bł. amplitudy	2,59	2,59	2,58	2,51	2,33	2,17	2,17
odsetek TN [%]	99,61	99,56	99,49	98,96	98,4	98,07	97,67

Sieć w zadowalający sposób radziła sobie z estymacją wartości wektora wyjściowego dla sygnałów niezawierających impulsów, prawidłowo podając wynik w około 99% przypadków dla mocy szumów od -5 do 10 dB. Dla większych mocy szumu odsetek ten spada o około 0,4% na każde dodatkowe 5 dB mocy szumu.

4.2. Model wytrenowany za pomocą impulsów gaussowskich

Do weryfikacji efektywności sieci w wariancie 1 dla impulsów gaussowskim użyto sygnałów o takich samych parametrach, jak w p. 3.2 i losowej wartości mocy szumu z przedziału od -5 do 20 dB.

Walidację skuteczności sieci, której wyniki przedstawiono w tab. 5, przeprowadzono w dokładnie taki sam sposób jak w przypadku modelu dla impulsów prostokątnych, z tą różnicą, że zastosowano impulsy gaussowskie o takich samych parametrach jak w danych treningowych.

Klasyfikacja sygnałów niezawierających impulsów pogorszyła się w stosunku do modelu dla impulsów prostokątnych i wyniosła od około 80% do 88%. Zaobserwowano, że dla klasyfikacji tych sygnałów wraz ze wzrostem mocy szumu pogorszyły się wskaźniki dla sygnałów zawierających impulsy.

Tab. 5. Wyniki walidacji drugiej sieci wytrenowanej za pomocą impulsów gaussowskich

moc szumu [dB]	-10	-5	0	5	10	15	20
średnia bł. początku	-4	-4	-6	-12	-28	-62	-110
odch. st. bł. początku	20,53	25,98	33,87	57,17	87,83	121,2	146,4
średnia bł. końca	2	1	0	-8	-33	-88	-174
odch. st. bł. końca	21,22	28,25	37,08	65,68	11,09	163,6	193
śr. bł. amplitudy	0,03	-0,02	-0,11	-0,32	-0,83	-1,74	-3,02
odch. st. bł. amplitudy	2,57	2,54	2,55	2,36	2,12	1,92	2,05
odsetek TN [%]	79,69	79,64	79,34	79,79	81,25	83,62	88,35

Średnie błędów estymacji pozycji impulsów i ich odchylenia standardowe rosły wraz ze wzrostem mocy szumu w danych walidacyjnych, przy czym odchylenia standardowe miały większe wartości w stosunku do wyników dla impulsów prostokątnych.

Wartości średnie błędów estymacji wartości amplitudy dla mocy szumu od -10 do 5 dB dawały wyniki na poziomie od -0,32 dla 5 dB do 0,03 dla -10 dB, co oznacza, że dla tych wartości sieć dosyć precyzyjnie wskazywała wyniki.

4.3. Testowanie za pomocą impulsów prostokątnych w obecności szumu i trendu.

Model sieci został wytrenowany sygnałami o takim samym charakterze jak w punkcie nieuwzględniającym trendu, lecz z dodatkowym trendem liniowym.

Wyniki walidacji modelu przedstawiono w tab. 6. Najbardziej zauważalną różnicę, w stosunku do sieci nieuwzględniającej trendu, jest znaczący spadek liczby prawdziwej predykcji dla sygnałów ich niezawierających. Dla większości mocy szumu, wynik stanowiły wartości mniejsze niż 50%, co jest znacznie gorszym wynikiem niż dla sieci nieuwzględniającej trendu.

Średnie wartości błędów estymacji początku i końca impulsów są niższe w porównaniu dla modeli bez trendu, a ich odchylenie standardowe większe o około 50% dla mniejszych wartości mocy szumów (od -5 dB do 5 dB). Dla wszystkich wartości mocy szumu w danych testowych sieć estymuje wartości amplitudy z niedomiarem, a odchylenie standardowe tych wartości rośnie wraz ze wzrostem mocy zakłóceń w sygnale.

Tab. 6. Wyniki walidacji sieci wytrenowanej za pomocą impulsów prostokątnych w obecności szumu i trendu

moc szumu [dB]	-5	0	5	10	15	20	25
średnia bł. początku	-3	-3	-3	-5	-7	-11	-22
odch. st. bł. początku	19,47	19,63	22,87	29,77	39,3	55,12	74,01
średnia bł. końca	-2	-2	-1	-2	-5	-16	-58
odch. st. bł. końca	15,59	17,95	21,96	31,32	50,35	79,1	130,1
śr. bł. amplitudy	-0,19	-0,22	-0,22	-0,3	-0,46	-0,61	-0,97
odch. st. bł. amplitudy	1,47	1,49	1,55	1,72	1,96	2,3	2,68
odsetek TN [%]	15,75	15,58	17,73	21,04	27,54	41,18	59,17

4.4. Testowanie za pomocą impulsów gaussowskich w obecności szumu i trendu.

Trening sieci w wariancie 2 za pomocą impulsów z p. 4.2, lecz z dodanym trendem liniowym okazał się nieefektywny. Wykres strat na przestrzeni treningu wskazywał na brak efektów uczenia się sieci, przez co wywnioskowano, że dodanie trendu do danych uniemożliwia sieci o zadanej architekturze naukę poprawnej detekcji impulsów w sygnałach o takim charakterze.

4.5. Testowanie wariantów za pomocą 5-krotnej walidacji krzyżowej

W celu sprawdzenia poprawności wytrenowanych modeli, przeprowadzono dla nich 5-krotną walidację krzyżową. Uzyskane wyniki dla danych treningowych i

walidacyjnych zbiegały do tej samej wartości na przestrzeni epok treningu, co wskazuje na brak przetrenowania i przecieków danych.

5. PODSUMOWANIE

W pracy przedstawiono dwie sieci neuronowe, które udało się zastosować do detekcji występowania impulsów oraz szacowania ich położenia oraz amplitudy szczytowej. Wyniki przeprowadzonych eksperymentów wskazują na to, że zmniejszanie SNR sygnałów niekorzystnie wpływało na detekcję impulsów w obu opracowanych wariantach sieci, od pewnego poziomu ją uniemożliwiając. Dodanie trendu liniowego obniżyło graniczną moc zakłóceń, przy których wyniki działania opracowanych modeli były zadowalające.

Wyniki uzyskane dla neuronowego detektora położenia i estymacji amplitudy impulsów jasno sugerują wpływ charakteru zbroczy impulsów na skuteczność detekcji, wskazując na korzystny wpływ bardziej stromych zbroczy na detekcję.

W przyszłych rozważaniach planowane jest przetestowanie innych, bardziej złożonych, architektur sieci neuronowych. Być może większa złożoność sieci pozwoli na zmniejszenie granicznej wartości SNR sygnałów, dla których detekcja jest skuteczna.

LITERATURA

- [1] Betka Szymon 2022, Zastosowanie sieci neuronowych do detekcji impulsów o znanym kształcie w obecności silnego szumu i trendu, projekt dyplomowy inżynierski, WETI PG
- [2] Hu J.-F. i in. 2015, "Harmonic signal detection method from strong chaotic background based on optimal filter" Acta Physica Sinica, vol. 64, no. 22, 220504.
- [3] Ke D. i in. 2019, "Blind detection techniques for non-cooperative communication signals based on deep learning," IEEE Access, vol. 7, pp. 89218–89225.
- [4] Liyun Su i in. 2019, "Detection and Extraction of Weak Pulse Signals in Chaotic Noise with PTAR and DLTAR Models", Mathematical Problems in Engineering, vol. 2019, 4842102.
- [5] Mendis G. J. i in. 2019, "Deep learning based radio-signal identification with hardware design," IEEE Transactions on Aerospace and Electronic Systems, vol. 55, no. 5, pp. 2516–2531.
- [6] Xing H.-Y. i in. 2012, "Detection of weak target signal with least-squares support vector machine and generalized embedding windows under chaotic background," Acta Physica Sinica, vol. 61, no. 10, 100506.
- [7] Yuan Y. i in. 2019, "DeepMorse: a deep convolutional learning method for blind Morse signal detection in wideband wireless spectrum," IEEE Access, vol. 7, pp. 8057–80587.
- [8] Yue L. i in. 2006, "Weak effective seismic signal detection capability of chaotic oscillator detection system," Chinese Science Bulletin, vol. 51, no. 14, pp. 1710–1716