

Wiktor WALENTYNOWICZ
wiktorwalentynowicz@hotmail.com

Ireneusz J. JÓŹWIAK
Politechnika Wrocławska
Wydział Informatyki i Zarządzania
ireneusz.jozwiak@pwr.edu.pl

STRATEGIA DOBORU PARAMETRÓW SIECI NEURONOWEJ W ROZPOZNAWANIU PISMA

Streszczenie. W pracy przedstawiono propozycje dobierania parametrów sieci neuronowej w celu usprawnienia wartości skuteczności sieci w rozpoznawaniu cyfr zapisanych pismem ręcznym. Sieć neuronową wyuczoną do tego celu utworzono przy użyciu biblioteki Keras. Analizie poddano parametry: momentum oraz współczynniki nauki i rozkładu. Artykuł zawiera badania, wnioski oraz wskazówki do dalszych badań dotyczących rozpoznawania pisma.

Słowa kluczowe: sieć neuronowa, rozpoznawanie cyfr, strategia, dobór parametru.

SELECTION STRATEGY OF THE NEURAL NETWORK PARAMETERS IN THE HANDWRITING RECOGNITION

Summary. The paper presents the problem of selection the parameters of neural network for increasing network performance. Trained neural network was created with Keras library. Analyzed parameters: momentum, learning rate and decay. The article contains researches, conclusions and advices for further research in the field of handwriting recognition.

Keywords: neural network, digit recognition, strategy, selection of the parameter.

1. Wprowadzenie

Wraz z rozwojem technologicznym ludzkość wykonuje coraz więcej pracy, którą da się zautomatyzować. Jednym z takich możliwych do automatyzacji problemów jest rozpoznawanie pisma ręcznego, a dokładniej – rozróżnianie znaków. Do tego zadania często wykorzystuje się sieci neuronowe, które przez możliwość ich wcześniejszego wyuczenia na setkach tysięcy przykładów osiągają bardzo dobre wyniki. Wraz z rozwojem dziedziny uczenia maszynowego i popularyzacji gotowych bibliotek programistycznych wzrosła liczba ludzi tworzących własne sieci zajmujące się wspomnianym problemem. Takie biblioteki, oprócz ustawionych domyślnie parametrów sieci wpływających na proces nauki, pozwalają na ustawienie ich samemu. Niestety najczęściej proponowane wartości parametrów podawane są bez wyjaśnienia, skąd wzięła się ich wartość. Z wymienionych powodów wynika cel niniejszej pracy: wskazanie sposobów zwiększenia wartości skuteczności sieci neuronowej.

W ramach poszukiwania rozwiązania podjęto próbę sprawdzenia tendencji wpływu poszczególnych parametrów na wyniki określające sprawność działania sieci neuronowej w rozwiązywaniu problemu rozpoznawania pisma ręcznego.

2. Sieć neuronowa rozpoznająca cyfry oparta na bibliotece Keras, zakres badań

Dziedzina rozpoznawania pisma ręcznego jest bardzo szeroka, w związku z tym do badań wybrano przypadek bardziej szczegółowy. Jest to rozpoznawanie cyfr zapisanych pismem ręcznym. Sieć neuronową wyuczoną do tego celu utworzono przy użyciu biblioteki Keras [3], służącej do łatwego modelowania sieci neuronowych w języku programowania Python.

Sieć miała architekturę 500-300-10 (500 neuronów w pierwszej warstwie ukrytej, 300 w drugiej warstwie ukrytej i 10 w warstwie wyjściowej) i 40% dropout [6] na warstwach ukrytych. Warstwa wejściowa posiadała 784 neurony wejściowe. Było to podyktowane zbiorem danych, na którym sieć była uczona i testowana. Był to zbiór MNIST [5], czyli zbiór obrazów cyfr zapisanych pismem ręcznym o rozmiarze 28x28 pikseli w skali szarości. Zbiór ten zawiera 60 000 przykładów treningowych i 10 000 przykładów testowych. Zbiór treningowy został podzielony na 50 000 przykładów uczących i 10 000 przykładów walidacyjnych. Jako funkcje aktywacji w warstwach ukrytych wykorzystano funkcje ReLU [2].

Analizie poddano następujące parametry:

1. Współczynnik nauki (ang. *learning rate*).
2. Ułamek wielkość poprzedniej aktualizacji (ang. *momentum*).
3. Współczynnik rozkładu (ang. *decay*).

Ad 1. Współczynnik nauki

Współczynnik nauki wpływa na wielkość kroku w algorytmie gradientu prostego, który jest wykorzystywany jako algorytm optymalizacji w procesie nauki sieci neuronowej. Kontroluje wielkość zmian wag neuronów.

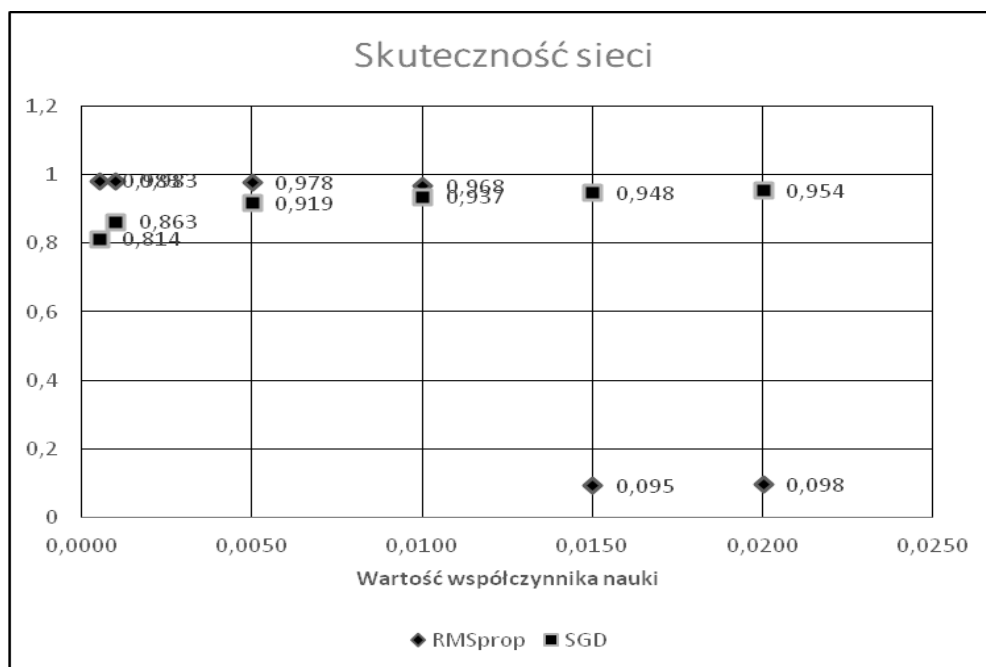
Ad 2. Wielkość poprzedniej aktualizacji – momentum

Momentum jest wartością dodawaną do aktualnie aktualizowanej wagi, równą ułamkowi wielkości poprzedniej aktualizacji. Używa się tego parametru w celu uniknięcia zbiegania do minimów lokalnych czy punktów siodłowych.

Ad 3. Współczynnik rozkładu

Współczynnik rozkładu zmienia swoją wartość, wielkość współczynnika nauki, po każdej epoce (zmianie wszystkich wag podczas epoki). Epoka to proces przetworzenia całego ciągu uczącego (czyli przepuszczenie przez sieć wszystkich przykładów uczących).

Na potrzeby badań zależności pomiędzy doбором współczynników a sprawnością sieci opracowano trzy scenariusze, z czego każdy skupiał się na innym czynniku: wpływ na wyniki sieci neuronowej przy zmianie współczynnika nauki, przy stałym współczynniku nauki i z zastosowaniem momentum oraz przy zmiennym współczynniku nauki poprzez współczynnik rozkładu. W przypadku badania wpływu wartości współczynnika nauki na wyniki sieci neuronowej zostały przebadane dwa algorytmy optymalizacji: RMSprop [4] oraz stochastyczny algorytm gradientu prostego (SGD) [1, 4]. W pozostałych przypadkach badanym algorytmem optymalizacji jest tylko SGD. W każdym badaniu sieć uczono przez czas 20 epok.



Rys. 1. Skuteczność sieci neuronowej w zależności od wartości współczynnika nauki

Fig. 1. The effectiveness of the neural network depending on values of learning rate

Źródło: Opracowanie własne.

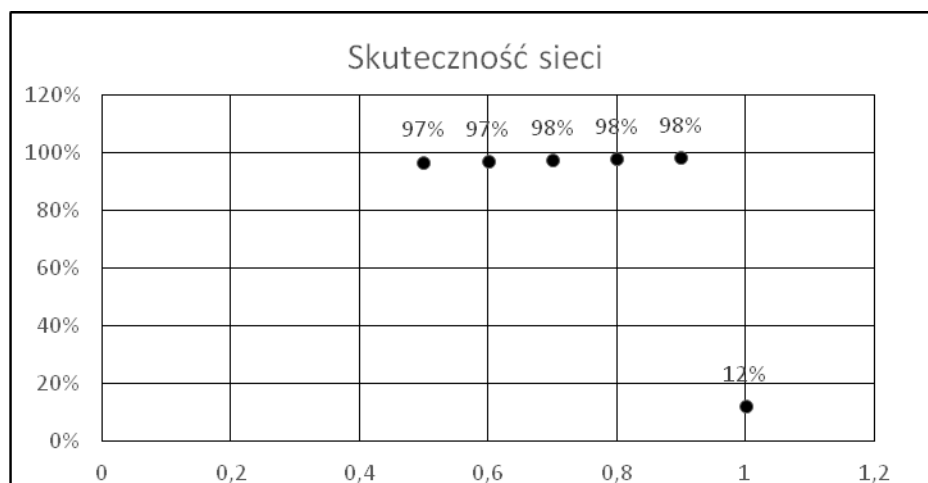
3. Wpływ współczynnika nauki

Aby określić wpływ, jaki ma współczynnik nauki, sprawdzano wyniki, które uzyskiwała sieć neuronowa po nauce na tych samych danych z różnymi wartościami współczynnika nauki dla dwóch różnych algorytmów optymalizacji. Przedział wartości współczynnika nauki to zbiór liczb rzeczywistych $\langle 0, 1 \rangle$.

Z przeprowadzonych badań wynika, że zależnie od wybranego algorytmu optymalizacji należy się kierować w zupełnie inną stronę przy doborze wartości początkowej współczynnika nauki. Algorytm RMSprop osiąga skuteczność 98% przy wartości 0,0005 i 0,001, a wraz ze wzrostem współczynnika nauki skuteczność spada, natomiast algorytm SGD osiąga skuteczność 95% przy wartości 0,02, a wraz z obniżaniem wartości współczynnika nauki skuteczność spada.

4. Wpływ wielkości poprzedniej aktualizacji – momentum

Aby określić wpływ wielkości poprzedniej aktualizacji, sprawdzano wyniki, jakie uzyskiwała sieć neuronowa po nauce na tych samych danych z różnymi wartościami momentum. Wartość współczynnika nauki wynosiła 0,02. Przedział wartości momentum to zbiór liczb rzeczywistych $\langle 0, 1 \rangle$.



Rys. 2. Skuteczność sieci neuronowej w zależności od wartości momentum

Fig. 2. The effectiveness of the neural network depending on values of momentum

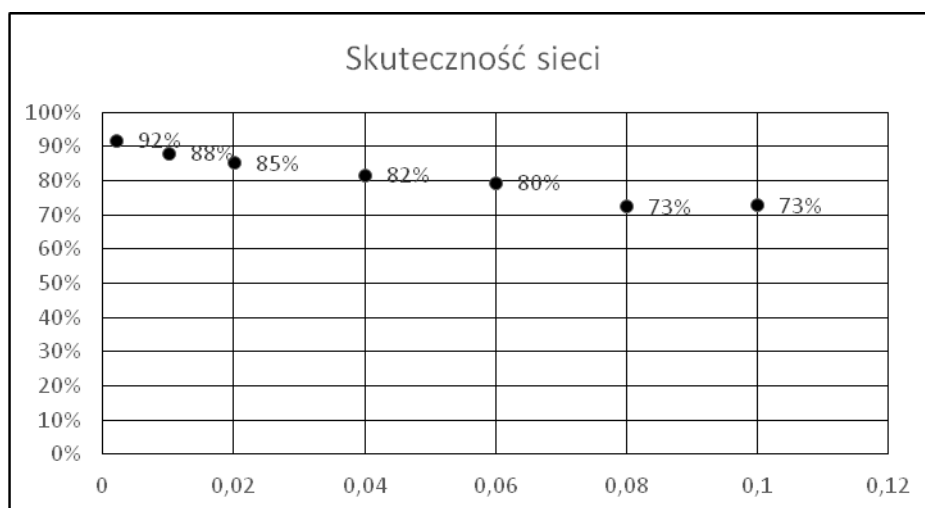
Źródło: Opracowanie własne.

Z przeprowadzonych badań wynika, że wartości momentum należy poszukiwać w okolicach 0,9. Wraz ze wzrostem wartości momentum skuteczność sieci rośnie, jednak przy

osiągnięciu wartości momentum równej 1 skuteczność sieci drastycznie spada. Jest to związane z przestrzeleniem minimum w procesie optymalizacji przez algorytm gradientu prostego.

5. Wpływ współczynnika rozkładu

Aby określić wpływ, jaki ma współczynnik rozkładu, sprawdzano wyniki, które uzyskiwała sieć neuronowa po nauce na tych samych danych z różnymi wartościami współczynnika rozkładu. Wartość współczynnika nauki wynosiła 0,02. Przedział wartości współczynnika rozkładu to zbiór liczb rzeczywistych $\langle 0, 1 \rangle$.



Rys. 3. Skuteczność sieci neuronowej w zależności od wartości współczynnika rozkładu

Fig. 3. The effectiveness of the neural network depending on values of decay

Źródło: Opracowanie własne.

Z przeprowadzonych badań wynika, że wartości współczynnika rozkładu należy poszukiwać w okolicach jak najmniejszych wartości. Wraz z obniżaniem wartości współczynnika rozkładu rośnie skuteczność sieci. Proponowana wartość współczynnika rozkładu to około 1% wartości współczynnika nauki.

6. Podsumowanie

Ważnym elementem wpływającym na poziom skuteczności sieci neuronowej jest dobór parametrów sieci. Aby dobrze dobrać te parametry, należy wiedzieć, jakie są tendencje

wpływu poszczególnych parametrów. Podane wyniki badań wskazują, jak zachowuje się wartość skuteczności sieci w zależności od wartości parametrów. Badania te pozwalają na wskazanie sposobów zwiększenia wartości skuteczności sieci neuronowej, co było celem pracy.

Nie oznacza to jednak, że tematyka podjętych w tym artykule badań została wyczerpana. Warto zastanawiać się nad równoczesnym doбором kilku parametrów i ich zależności względem siebie.

Bibliografia

1. Bottou L.: Large-scale machine learning with stochastic gradient descent. Proceedings of COMPSTAT'2010. Physica-Verlag HD, 2010, p. 177-186.
2. Glorot X., Bordes A., Bengio Y.: Deep Sparse Rectifier Neural Networks. Aistats, vol. 15, No. 106, 2011.
3. Keras: Deep Learning library for Theano and TensorFlow, <https://keras.io/> (20.08.2016).
4. Diederik K., Ba J.: Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980 (2014).
5. MNIST database, <http://yann.lecun.com/exdb/mnist/> (20.08.2016).
6. Nitish S., et al.: Dropout: a simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, vol. 15, No. 1, 2014, p. 1929-1958.

Abstract

Nowadays it is possible to automate the recognition process of the handwriting to the purpose of the significant acceleration of that process. Using neural networks recognizing individual signs is one of methods. With important component during the process of teaching the neural network there is a selection of neural network parameters associated with the learning process. Researches in the article focussed on increasing the efficiency of the network through the change of these parameters. Learning rate, momentum and decay were analysed parameters. Thanks to conducted researches relations were noticed between the selection of the value of the parameter and the level of the effectiveness networks and they presented how to select parameters if only to achieve as the greatest results. In the end of article more distant research directions were suggested in the field of handwriting recognition.