

University of Mosul
College of Engineering



Deep Learning Classification of Brain Neurophysiological Signals Using Cut- Concatenation

A Ph.D. Thesis

submitted by

Ali Mukhlif Ahmed Al-Saegh

Supervised by

Prof. Dr. Shefa A. Dawwd

Prof. Dr. Jassim M. Abdul-Jabbar

Abstract

The non-invasive Electroencephalogram (EEG) signals permit people communicating with devices and having control over them in what is normally called a Brain-Computer Interface (BCI) system. Nowadays, the Motor Imagery (MI) EEG-based BCI technology is becoming favorable due to its massive applications in both medical and non-medical implementations.

The current revolution of Deep Learning (DL) has permitted both feature extraction and classification jointly for the analysis of different data types. However, DL is a data learning approach that requires a large number of training samples to train large-scale neural networks. However, the EEG research field lacks a large amount of data which restricts the use of DL within this field.

This research proposes a novel data augmentation method for enlarging already available EEG datasets. The proposed Cut Concatenate (CutCat) augmentation method generates EEG trials from inter- and intra-subjects and trials. The method relies on cutting a specific portion from an EEG trial and concatenating it with another portion from another trial from the same subject or different subjects. The method has been tested on shallow and Deep Convolutional Neural Networks (DCNN) for the classification of motor imagery MI EEG data. The experimental results demonstrate that the proposed augmentation method is a promising strategy for handling the classification of small-scale datasets. Whereas, an improvement of 14% and 10% for both shallow and deep networks have been registered, respectively.

Moreover, DL requires intensive matrix Multiply-And-Accumulate (MAC) operations for a network to be trained and for an input sample to be inferred. Also, the complexity of the trained model is high and hence inference process could be slow. Hence, this study aims to reduce those two complexities of computations using data reduction and quantization techniques. Data reduction leads to a smaller size of a training batch, thus expediting the training process. Quantization means fewer bits are used for representing the learnable parameters of the trained DCNN. Training elapsed time has been reduced by about 25% with a negligible classification accuracy drop (0.6%). Moreover, using 8-bit fixed-point data type has improved the inference speed by 2.7x and reduced the storage memory by 75%.

الملخص

إن إشارات الدماغ الكهربائية (EEG) المستحصلة بطرق غير جراحية قد مكنت الإنسان من التعامل مع الأجهزة المحيطة به والتحكم بها بما يسمى عادة بنظام واجهة الدماغ والحاسوب (BCI). في الوقت الحاضر أصبحت تقنية BCI المستندة إلى إشارات الدماغ التخليقية MI EEG مواتية بسبب تطبيقاتها الضخمة في كل من الجوانب الطبية وغير الطبية. لقد مكنت الثورة الأخيرة في التعلم العميق (DL) من إستخلاص الميزات وتصنيفها بطريقة ترابطية لتحليل أنواع البيانات المختلفة. ولكن DL عبارة عن نهج تعلم من البيانات نفسها حيث أنه يتطلب عددا كبيرا من العينات لتدريب الشبكات العصبية الكبيرة الحجم والتي تتكون من أكثر من طبقتين من الخلايا العصبية. في حين أن مجال أبحاث EEG يفتقر إلى كمية كبيرة من البيانات والذي يقيد استخدام DL في هذا المجال.

يقترح هذا البحث طريقة جديدة لزيادة العينات المتوفرة في مجموعات بيانات EEG المتوفرة بالفعل. إن الطريقة المقترحة لزيادة البيانات والتي تم تسميتها (CutCat) تولد عينات تدريب جديدة من بين العينات المتوفرة للشخص الواحد وكذلك لعدة أشخاص. تعتمد الطريقة على قطع جزء معين من عينة EEG وربطها بجزء آخر من عينة أخرى تابعة لنفس الشخص أو لشخص آخر. تم اختبار الطريقة على الشبكات العصبية التلافيفية (CNN) الصغيرة الحجم وكذلك الكبيرة الحجم والتي تسمى بالشبكات العصبية العميقة (DNN) لتصنيف بيانات MI EEG. توضح النتائج المستحصلة من التجارب أن طريقة الزيادة المقترحة هي إستراتيجية واحدة للتعامل مع تصنيف مجموعات البيانات الصغيرة الحجم. وقد أظهرت نتائج التصنيف على مجموعتي بيانات MI EEG تقدما بدقة التصنيف بالمقارنة مع نتائج الأبحاث الحديثة. حيث كان هناك تحسين في دقة التصنيف بمقدار 14% للشبكة صغيرة الحجم وكذلك 10% للشبكة العميقة.

بالإضافة إلى مشكلة قلة بيانات EEG لتدريب الشبكات الكبيرة الحجم، هناك نوعان من القيود الرئيسية التي تواجه اعتماد DL في التطبيقات الحقيقية. أولاً، تتطلب DL عمليات كثيفة من الضرب والجمع (MAC) على مصفوفات كبيرة الحجم لغرض تدريب شبكة عصبية عميقة وكذلك لتصنيف عينة إدخال. ثانياً، تكون عملية التصنيف بطيئة بسبب التعقيد الموجود في تلك الشبكات المدربة.

لذلك ومن ضمن الأهداف الأخرى لهذه الدراسة هو التقليل من تعقيدات الحسابات التي تم ذكرها. حيث يتم ذلك من خلال إستخدام تقنيات تقليل البيانات والتكميم. يؤدي تقليل البيانات إلى حجم أصغر لدفعة التدريب من العينات، وبالتالي تسريع عملية التدريب. يعني التكميم إستخدام عدد أقل من وحدات الخزن الرئيسية (bits) لتمثيل المعاملات القابلة للتعلم لشبكة تلافيفية عميقة مدربة. أثبتت نتائج التجارب فائدة طرق تقليل البيانات، حيث تم تقليل الوقت المطلوب للتدريب بنسبة 25% مع إنخفاض غير معتبر في دقة التصنيف (0.6%). حيث أنه تم الحصول على تسريع يبلغ 2.7 ضعف وتقليل ذاكرة التخزين بنسبة 75% بإستخدام نوع بيانات النقطة الثابتة 8-bit.



جامعة الموصل
كلية الهندسة

التصنيف بالتعليم العميق لإشارات الخلايا العصبية في الدماغ بإستخدام القطع والتسلسل

أطروحة دكتوراه
مقدمة من قبل
علي مخلف أحمد الصائغ

بإشراف
الأستاذ الدكتور شفاء عبد الرحمن داؤد
الأستاذ الدكتور جاسم محمد عبد الجبار