

## Enhancement of Traffic Lights Recognition process using Deep Learning based on SqueezeNet

Magdolien Abdulmageed Husain \*

(Received 28 / 2 / 2019. Accepted 8 / 5 / 2019)

### □ ABSTRACT □

Artificial Intelligence(AI) and Machine Learning(ML) are some of the hottest topics right now. Once you've read this article, you will understand the basics of AI and ML,the most important branch of Machine Learning is Deep Learning(DL).

There are lots of applications about Deep Learning, now we will discuss Recognizing of Traffic Lights state in any photo taken by *Nexar* application. We were compelled to explain extra conceptions from Image Processing such image rotation and day and night separating. [2,3]

All researches depend on the model accuracy and model size with MB,where the smallest model take the higher score.

Using of many models and intersecting the results improve the accuracy, so we have used the models reassembling.At the end,we get a model with accuracy 94.83%

and model size 7.84MB Whereas the model accuracy on Nexar samples was 94.955%.

SqueezeNet has been relying on smaller models as well as having pre-trained models using Image Net.

**Key Words:** Artificial Intelligence, Machine Learning, Image Processing.

---

\* Academic Asisstant at Department of Computers and Automatic Contol Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syrian Arab Republic.

## تحسين عملية التعرف على إشارات المرور باستخدام التعلم العميق باعتتماد على شبكة SqueezeNet

ماجدولين عبد المجيد حسين\*

(تاريخ الإيداع 28 / 2 / 2019. قُبِلَ للنشر في 8 / 5 / 2019)

### □ ملخّص □

أصبح مصطلح الذكاء الصناعي وتعلم الآلة أكثر المواضيع المتداولة في وقتنا الحالي، يساهم هذا البحث بتعليم أساسيات الذكاء الصناعي وتعلم الآلة والشيء الأكثر أهمية أن تعرف أن التعلم العميق يعتمد على تدريب الشبكات العصبية في أحد شكلي التدريب بإشراف أو بدون إشراف. هناك تطبيقات هائلة للتعلم العميق، نركز في هذا البحث على التعرف على حالة إشارة المرور في أي صورة مأخوذة عن طريق تطبيق نيكسار. وكان لابد من الاستعانة ببعض المفاهيم من مجال معالجة الصورة كشرح تدوير الصور وفصل الليل و النهار عن طريق فحص معدل كثافة البكسل [2,3]. جميع الأبحاث تركز على دقة النموذج بالتوازي مع حجم النموذج بالميجابايت حيث النموذج الأصغر يأخذ الدرجات الأعلى. إن استخدام عدة نماذج مع بعضها البعض و مقاطعة النتائج يحسن الدقة بشكل جيد، لذا استخدمنا تقنية تجميع النماذج حيث حصلنا على دقة النموذج على عينات الصلاحية كانت %94.83، بحجم نموذج 7.84 ميغابايت حيث أن دقة النموذج على عينات اختبار نيكسار هي %94.955 . تم الاعتماد على شبكة SqueezeNet كونها تعتمد نماذج أقل إضافة إلى امتلاكها نماذج مدربة مسبقا باستخدام Image Net.

الكلمات المفتاحية: الذكاء الصناعي، تعلم الآلة، التعلم العميق، معالجة الصورة.

\* قائم بالأعمال ، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية ، سورية.

**مقدمة :**

ظهر التعلم العميق (التعلم عميق البنية) عام 2006 كمجال جديد ضمن بحوث تعلم الآلة ويستخدم عدة طبقات من المعالجة غير الخطية للمعلومات لاستخراج ونقل الخواص بإشراف أو بدون إشراف بالإضافة لتحليل و وتصنيف الأنماط. إن الخطوة الأولى لفهم التعلم العميق هي معرفة الاختلاف بين عدة مفاهيم.

**1 الذكاء الصناعي و تعلم الآلة:**

يُعد الذكاء الصناعي ترسيخاً لذكاء الإنسان في الحواسيب الرقمية وعندما ظهر أول بحث في الذكاء الصناعي حاول الباحثون حصر الذكاء الصناعي في مجالات محددة كالألعاب وقد قدموا عدداً كبيراً من القواعد التي يحتاجها الحاسب، حيث أن الحاسب لديه قائمة محدودة من الأفعال والقرارات التي يتخذها اعتماداً على تلك القواعد. تعلم الآلة يشير إلى قدرة الآلة على التعلم باستخدام مجموعات كبيرة من البيانات بدلاً من قواعد مبهم، وهو يسمح للحواسيب أن تعلم نفسها وهذا التعلم يتقدم على قدرة المعالجة للحواسيب الحديثة والتي بسهولة تعالج مجموعه كبيرة من البيانات[5].

**2 التعلم بإشراف والتعلم بدون إشراف:**

إن التعلم بإشراف أو التعلم الاستقرائي هو منهج في تعلم الآلة يقوم باستنتاج تابع من مجموعه بيانات تدريبية مفهرسة [2]، تتكون بيانات التدريب من مجموعه من الأمثلة الواقعية (بيانات مريض في مستشفى، قيمة الاسهم في البورصة). في التعلم تحت الاشراف كل عينة تمثل شيء على ارض الواقع وتتكون من زوج بيانات دخل و خرج، تحلل خوارزمية التعلم بإشراف بيانات التدريب وينتج تابع الاستدلال الذي يستخدم في تعيين الامثلة الجديدة باستخدام مجموعه بيانات مصنفة تملك دخلاً و خرجاً محدداً عندما تدرّب باستخدام التعلم بإشراف ستعطي الشبكة دخلاً و خرجاً متوقفاً منها، فإذا كان الخرج الناتج خاطئ فإنها ستعيد تعديل حساباتها بشكل متكرر حتى نفاذ الأخطاء. وكمثال عن التعلم بإشراف هو التنبؤ بحالة الطقس حيث تتدرب الشبكة لتتنبأ بحالة الطقس باستخدام بيانات التدريب والتي هي عبارة عن (الضغط-الرطوبة-سرعة الرياح) والخرج عبارة عن درجة حرارة الطقس.

من ناحية أخرى، فإن التعلم بدون إشراف (التعلم غير المراقب او التعلم الاستنتاجي) هو أحد الفروع الرئيسية في مجال تعلم الآلة و الذكاء الصناعي والشبكات العصبونية الاصطناعية الذي يهتم بخوارزميات تعلم الآلة عن طريق تمييز أنماط بيانات دون أن تكون هذه البيانات معنونه [6] . عندما تتدرب الشبكة باستخدام التعلم دون إشراف فإننا نترك الشبكة تضع تصنيفاً منطقياً للبيانات، و كمثال عن التعلم بدون إشراف هي التجارة عبر المواقع الالكترونية، حيث لا تتدرب الشبكة باستخدام مجموعه بيانات مصنفة للدخل والخرج بل بدلا من ذلك سوف تخلق تصنيفها الخاص للدخل وتخبرك أي نوع من المستخدمين الأكثر احتمالاً لشراء منتجات مختلفة عبر الانترنت.

**أهمية البحث وأهدافه:**

يهدف هذا البحث إلى بناء مصنف يعتمد على تقنيات الذكاء الصناعي والتعلم العميق باستخدام الشبكات العصبونية الالتفافية للتعرف على حالة اشارة المرور في الصور المأخوذة من قبل السائقين باستخدام تطبيق نيكسار مما يمكن من الحصول على حماية أثناء قيادة السيارة فهو يوفر للمستخدم رصد الحوادث الخطيرة التي يمكن أن يتعرض لها على الطريق أثناء القيادة.

## طرائق البحث و موادہ:

تم استخدام تقنية Caffe ، وهي تقنية تعلم عميق معد بسرعه وجزئية وتكامل في الدماغ طورت من قبل بيركلي [7] ، لتدريب النماذج والسبب الرئيسي لاستخدام هذه التقنية كان بسبب التنوع الكبير للنماذج المدربة مسبقا. كما تم استخدام لغة البايثون، مكتبة Numpy وتطبيق Jupyter Notebook (تطبيق مفتوح المصدر يسمح بإنشاء ومشاركة الوثائق) لتحليل النتائج واكتشاف البيانات.


## آلية عمل التعلم العميق:

يسمح لنا التعلم العميق أن ندرّب الشبكة العصبية لتتنبأ بالخرج بعد إعطائها الدخل المناسب، إن كل من التعلم بإشراف والتعلم بدون إشراف يمكن استخدامه لتدريب الشبكات العصبية.

في هذه الفقرة نبين كيف يساهم التعلم العميق بإنشاء الخدمة الافتراضية اللازمة ونبين كيف يتم تدريب الشبكة العصبونية باستخدام خوارزميات التعلم بإشراف ويهدف إعطاء التنبؤات المرغوبة باستخدام المدخلات المتوفرة.

أولاً: بناء الشبكات العصبونية:

إن الشبكة العصبية تحتوي على عصبونات تمثل بدوائر و يمكن أن تتصل داخلياً وفق عدة طبقات من العصبونات مختلفة العدد، كما هو مبين في الشكل (1) [8]، إن هذه العصبونات يتم تنظيمها في ثلاثة أنواع مختلفة من الطبقات و هي: طبقة الدخل و الطبقات الداخلية و طبقة الخرج.



الشكل (1)، مكونات الشبكة العصبونية [5].

من أجل المثال المدروس فإن طبقة الدخل التي تستقبل البيانات المدخلة وتحتاج الى عدد محدد من العصبونات بينما طبقة الخرج هي من تعيد بيانات الخرج ومن ناحية أخرى فإن الطبقات المخفية تنجز العمليات الرياضيه الضرورية على المداخل وأحد أهم الصعوبات في إنشاء الشبكات العصبونية هو تحديد عدد الطبقات المخفية وعدد العصبونات في كل طبقه، و هنا تجدر الإشارة أن كلمه عميق في مصطلح التعلم العميق تشير الى امتلاك اكثر من طبقة خفية داخل الشبكة العصبونية [11,12].

ثالثاً: تدريب الشبكة العصبونية:

يعد تدريب الشبكة العصبونية الجزء الأصعب من التعلم العميق و ذلك نظرا للأسباب التالية:


- تحتاج إلى فضاء عينة واسع.
- تحتاج إلى قدرات حسابية كبيرة.

حالما نعبر عن فضاء العينة كاملاً نستطيع انشاء تابع يعرض لنا مقدار الخطأ بين المخارج الناتجة و المخارج المثالية، هذا التابع يسمى تابع الكلفة بشكل مثالي نهدف أن يتناقص حتى يتناقص تابع الكلفة، وبدلاً من تغيير الأوزان بشكل عشوائي سنستخدم تقنية تدعى Gradient Degree GD [8,9] في مثالنا المدروس، وهي تقنية تسمح لنا بإيجاد الحد الأدنى للتابع المدروس و في حالتنا هذه نبحث عن الحد الأدنى لتابع الكلفة.

رابعاً: تقليل تابع الكلفة:

نغير الأوزان بين العصبونات ، يتم تقليل تابع الكلفة من خلال تغيير الأوزان بين العصبونات في الشبكة وذلك بشكل عشوائي حتى يتناقص تابع الكلفة، إلا أن هذه الطريقة غير فعالة، وبدلاً من تغيير الأوزان بشكل عشوائي سنستخدم تقنية تدعى Gradient Degree GD [8,9] في مثالنا المدروس، وهي تقنية تسمح لنا بإيجاد الحد الأدنى للتابع المدروس و في حالتنا هذه نبحث عن الحد الأدنى لتابع الكلفة.

تعمل هذه التقنية عن طريق التغيير في الأوزان بزيادات صغيرة بعد كل تكرار لفضاء العينة عن طريق حساب الميل أو المشتق لتابع الكلفة لمجموعه محددة من الأوزان، وبالتالي يصبح بمقدورنا رؤية في أي اتجاه القيمة الدنيا له كما هو موضح في الشكل (4) [8]:



الشكل (4). تقنية الـ GD

تقليل تابع الكلفة بحاجه لقدرات رياضية عالية بينما تعديل الأوزان باستخدام تقنية GD ينجز تلقائياً و هذا هو سر التعلم العميق.

التعرف على ألوان إشارة المرور باستخدام التعلم العميق:

إن الهدف من البحث هو أن نتعرف على حالة إشارة المرور في الصور المأخوذة من قبل السائقين باستخدام تطبيق نيكسار (Nexar Application) [9,11] والذي هو من أهم تطبيقات Dashcam و يمكن من الحصول على حماية أثناء قيادة السيارة فهو يوفر للمستخدم رصد الحوادث الخطيرة التي يمكن أن يتعرض لها على الطريق أثناء القيادة. في أي صورة معطاة، يكون المطلوب من المصنف أن يعطي خرج فيما إذا وجد ضوء في المشهد وفيما إذا كان الضوء أحمر أو أخضر، وبتحديد أكثر يجب أن يحدد فقط ألوان إشارة المرور في اتجاه القيادة، وفي الشكل (5) يظهر أمثلة على الأصناف الثلاث الممكنة، وهنا نكون بحاجة للتنبؤ بثلاث حالات و هي :

- 1- لا يوجد ضوء إشارة مرور (صورة أ).
- 2- ضوء أحمر (صورة ب).
- 3- ضوء أخضر (صورة ج).



(صورة ج)

(صورة ب)

(صورة أ)

الشكل(5)، الأصناف الثلاثة الممكنة التي يمكن أن يواجهها المصنف.

تطلب البحث أن يكون الحل معتمداً على الشبكات العصبية الالتفافية، وهي عبارة عن تطبيق شائع جداً يستخدم في مجال التعرف على الصورة باستخدام الشبكات العصبية العميقة. معظم الأبحاث في هذا المجال تعتمد على دقة النموذج بالتوازي مع حجم النموذج (بالميجابايت) حيث النموذج الأصغر حجماً يأخذ الدرجات الأعلى بالإضافة إلى أن الدقة الأقل المطلوبة للفوز هي 95%.

يؤمن تطبيق نيكسار 180659 صورة مفهوسة كبيانات تدريب وكل صورة معنونه بواحد من ثلاث أصناف مذكورة في الأعلى (لا يوجد ضوء، ضوء أحمر، ضوء أخضر).

#### بناء المصنف النهائي:

يستخدم المصنف مجموعة من ثلاث شبكات مدربة و منفصلة، المتوسط المرجح من الاحتمالات أن تعطي هذه الشبكات لكل صنف استخدم كخرج كل ثلاث شبكات قد استخدمت شبكة SqueezeNet [12,7] لكن كل شبكة تدريب بشكل مختلف.

#### النموذج الأول: شبكة مدربة مسبقاً بتقطيع العينات:

تم التدريب على بيانات مدربة معاد فهرستها بعد تثبيت أخطاء ال ground truth ، النموذج كان معياراً بشكل جيد بالاعتماد على النموذج المدرب مسبقاً لشبكة SqueezeNet المدربة على ImageNet.

#### النموذج الثاني: إضافة ثابتية للدوران:

هذا النموذج مشابه جداً للنموذج الأول مع إضافة تدوير للصورة أثناء التدريب كانت الصور تدور عشوائياً بزوايا  $90^\circ$ – $180^\circ$  أو لا تدور أبداً.

#### النموذج الثالث: التدريب من سكراتش

هذا النموذج لم يعاير بشكل جيد لكنه عوضاً عن ذلك تدريب من سكراتش الأمر الجوهري وراء ذلك بالرغم من أنه ينجز دقة أقل لكنه يتعلم ميزات مختلفة على عينات التدريب من النموذجين السابقين.

#### اختبار المصنف النهائي:

حقق المصنف النهائي دقة 94.955 % على عينات اختبار نيكسار مع حجم نموذج 7.8MB بالمقارنة مع GoogleNet الذي يستخدم حجم نموذج 41MB و VGG-16 الذي يستخدم حجم نموذج 528 MB.

كانت البداية في محاولة أن نقوم بعملية ضبط دقيق للنموذج المدرب مسبقاً على قاعدة البيانات Image Net و هي قاعدة بيانات للصور الرقمية منظمة حسب معمارية word Net حالياً فقط على الأسماء حيث في كل عقدة من المعمارية توجد آلاف الصور حالياً بمعدل وسطي يوجد حوالي 500 ألف صورة/عقدة، و تم استخدام تقنية GoogLeNet في عملية ضبط النموذج المدرب حيث ذكر تطبيق نيكسار في صفحة التحدي أنه من الممكن أن يصل إلى دقة 93% عبر الضبط الدقيق لـ GoogLeNet.

#### اختبار تدوير الصورة:

معظم الصور كانت أفقية و لكن حوالي 2,4% منها كانت عمودية وبكل أنواع الاتجاهات للأعلى و على الرغم من أن مثل هذه الصور لا تشكل قسماً كبيراً من فضاء العينة، لكن أيضاً كان الهدف هو أن يقوم النموذج بتصنيفها بشكل جيد.

لسوء الحظ لا يوجد بيانات EXIF (Exchangable Image File) في صور JPEG، لذا أخذ بعين الاعتبار عمل بعض الارشادات لتعيين الفضاء وقلب الصورة وفقاً لذلك تم تدريب الشبكة بزوايا عشوائية (0°-90°-180°-270°) فكان هناك معدل تنبؤات بأربع اتجاهات للصور (94.2% - 94%).

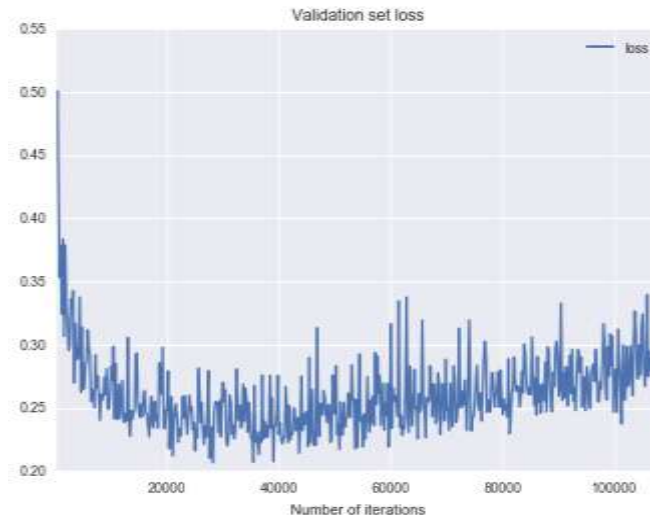
#### أخذ العينات:

خلال تدريب شبكة SqueezeNet تم في البداية تقطيع عشوائي على الصور المدخلة، وهذا النوع من معالجة البيانات بالعموم يجعل أداء الشبكة أفضل.

بشكل مشابه بعد انتاج توقعات اخذت عدة عينات من الصور المدخلة وتم تحديد المتوسط الحسابي للنتائج باستخدام خمس عينات (أربع منها زوايا وعينة مركز)، أبدى تدوير الصور معا بتقطيع العينات تحسيناً جيداً 94. → 94% 6%

#### تدريب إضافي بمعدل نقل أقل:

كل النماذج كانت قد بدأت بالدخول في حالة (overfit) عملية تناقص خطأ التدريب مع زيادة خطأ الصلاحية بعد نقطه محددة. لوحظ ذلك بمشاهدة أن منحنى صلاحية فقد العينات بدأ بالتزايد عند نقطه محددة، حوالي (43500) الشكل (6).



الشكل (6) مشكلة الـ overfitting

تم إيقاف التدريب في تلك النقطة لأن النموذج كان من المحتمل أن لا يعمم أكثر من ذلك و هذا يعني أن معدل التعلم لا يملك وقت ليتناهي الى الصفر. تمت محاولات إكمال عملية التدريب في تلك النقطة حيث النموذج بدأ بالـ overfitting بمعدل تعلم أقل ب 10 مرات من المعدل الأصلي و هذا سوف يحسن الدقة %0.56-0 .

#### اختبار اضافة بيانات تدريب أكثر:

في البداية تم تقسيم بيانات التدريب إلى ثلاث مجموعات:

1- بيانات تدريب بنسبة %62.

2- بيانات صلاحية بنسبة %18.

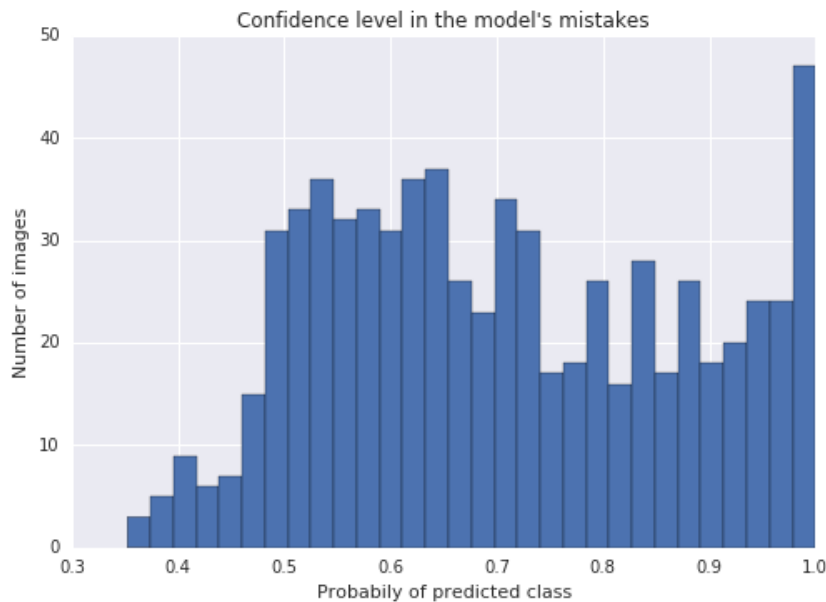
3- بيانات اختبار بنسبة %20.

إن فكرة التحلي عن %38 لم تتم مناقشتها لأن هذا الكم من البيانات قد يكون كثيرا لذا تم دمج مجموعتي التدريب و الصلاحية و تم الإبقاء على مجموعه الاختبار لاختبار النتائج.

تمت إعادة تدريب النموذج بتدوير الصورة و بالتدريب الاضافي بمعدل نقل أقل و لوحظ وجود تحسينات من %93.6 إلى %94.35

#### اختبار إعادة تعريف الأخطاء في بيانات التدريب:

عند تحليل الأخطاء التي يرتكبها المصنف على عينات الصلاحية لوحظ أن بعض الأخطاء لديها موثوقية عالية، بمعنى آخر عندما حدد النموذج أمراً ما (اللون الاخضر مثلا) أشارت بيانات التدريب الى شيء آخر تماماً (ضوء احمر)، بملاحظه الشكل (7) يبدو من القسم اليميني أنه مرتفع و هذا يعني وجود عدد كبير من الاخطاء بموثوقية اكبر من %95.



الشكل (7)، الموثوقية عبر أخطاء النموذج



عند فحص حالات الأخطاء هذه تبين أنها تكون عادة أخطاء في ground-truth، و هو مصطلح يشير إلى دقة تصنيف بيانات التدريب [12]، أكثر مما هي أخطاء في النموذج المدرب . تم دمج هذه الأخطاء في عينات التدريب حيث أن هذه الأخطاء يمكن أن تشوش النموذج و تجعل تعميمه أصعب حتى و إن كان الاختبار النهائي للعينات لديه اخطاء في Ground-Truth، فالنموذج الاكثر تعميماً لديه فرصه أفضل لدقة أعلى للصور .

تمت عملية فهرسة 735 صور رقمية يدوياً و هذا يغير من ال Ground-Truth لـ 337 صورة من أصل 735 صورة. وهذا يستغرق ساعة من العمل اليدوي باستخدام python script ليكون العمل أكثر فاعلية. يظهر في الشكل (8) نفس المخطط في الشكل (7) لكن بعد إعادة تعريف الأخطاء و إعادة تدريب النموذج ونلاحظ وجود تحسين للنموذج السابق بمقدار 94.5% → 93.2%.



الشكل (8)، overfitting، بعد إعادة تعريف الأخطاء

### تجميع النماذج:

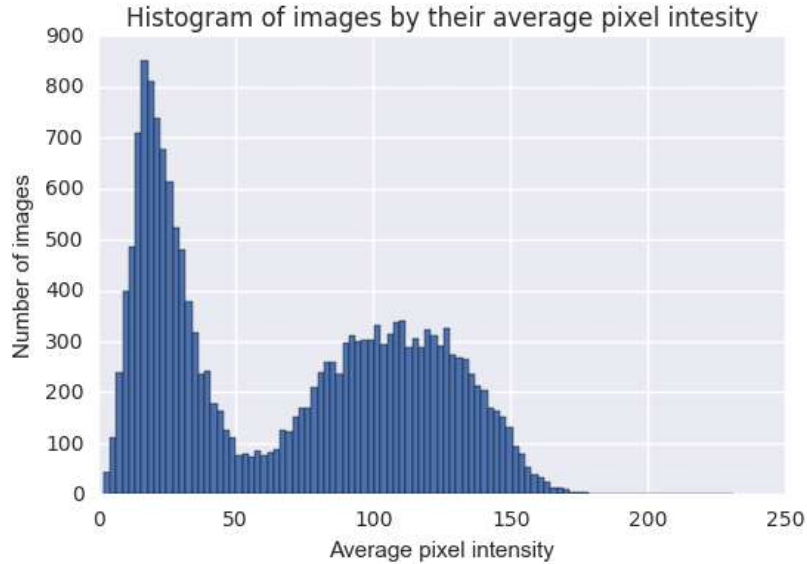
إن استخدام عدة نماذج مع بعضها البعض ومقاطعة النتائج يحسن الدقة بشكل جيد. تم تجريب أنواع مختلفة من التعديلات في عملية تدريب النموذج و حقق تحسناً ملحوظاً باستخدام نموذج مدرب من سكراتش (لغة برمجة). يستخدم هذا التجميع عدة نماذج بدقات: 94.1% , 94.2% , 94.9% و معا كانت الدقة 94.8%.

### اختبار وجود ال Overfitting:

أثناء التعامل مع ال Overfitting تم تجريب العديد من المحاولات إلا أنها لم تبد أي تحسينات ملحوظه، وتشمل هذه المحاولات: زيادة نسبة الانحدار في الشبكة ومناقشة بيانات أكثر (إزاحة-تكبير-انحراف) و التدريب على بيانات أكثر (استخدام تقسيم 90/10 بدلا من 80/20)

### اختبار فصل الليل والنهار:

كان الهدف هو التعرف على أضواء إشارة المرور في النهار و في الليل، و في مجال معالجة الصورة الرقمية فإنه من السهل نوعاً ما فصل الصور إلى ليل و نهار بالنظر إلى معدل كثافة البيكسل كما هو مبين في الشكل(9).



الشكل(9)، تميز الصور في الليل و النهار باستخدام معدل كثافة البيكسلات.

تم تجريب مقاربتين هما

- تدريب النموذجين المنفصلين لصور النهار وصور الليل.
  - تدريب الشبكة لتتنبأ بستة أصناف بدلاً من ثلاثة بإضافة توقع الليل و النهار.
- إلا أن كلاهما لم يجد نفعاً.

- مناقشة النتائج

اختبار توضع أضواء إشارة المرور:

تم تدريب النموذج على معرفة موضع إشارة المرور بالنسبة للصورة أولاً ومن ثم تحديد حالة ضوء إشارة المرور في منطقة صغيرة من الصورة ثانياً، وتم استخدام الأداة Sloth لعنونة حوالي 2000 صورة واستغرق ذلك بضع ساعات. و نبين في الشكال التالية (10-11-12)

## - أمثلة على أخطاء النموذج:



الشكل(10)

النقطة الخضراء في شجرة النخيل تعطي وهجا يجعل النموذج يتوقع أنه ضوء أخضر من باب الخطأ.



الشكل(11)

يتوقع النموذج اللون الأحمر بدلا من الأخضر. الحالة الأصعب هي وجود أكثر من ضوء اشارة في المشهد.



الشكل(12)

يتوقع النموذج أنه لا يوجد ضوء اشارة مرور بينما حقيقة يوجد ضوء أخضر للأمام.

### الاستنتاجات و التوصيات:

تدريب النموذج ساهم في تحديد ومعرفة موضع إشارة المرور بالنسبة للصورة أولاً ومن ثم تحديد لون ضوء إشارة المرور في الصورة كمرحلة ثانية.  
من الأفضل أن يتم عنونة بيانات أكثر عند تكرار محاولة تدريب النموذج حتى يحقق نتائج أفضل ولا ينهار بسرعه.

### المراجع

1. GOODFELLOW,I; BENGIO,U; COURVILLE,A, *Deep Learning* .America, 2016.
2. DENG,L.;YU,D., *Deep Learning Methods and Applications*,China,2014.
3. BENGIO, Y. *Learning Deep Architectures for AI Foundations and Trends in Machine Learning*, Canada,2009
4. BENGIO,Y.; COURVILLE,A.; VINCENT, P. , *Representation Learning: A Review and New Perspectives*. IEEE Transactions on Pattern Analysis and Machine Intelligence. 35 (8): 1798–1828.2013
5. SCHMIDHUBER, J., *Deep Learning in Neural Networks: An Overview*. Neural Networks. America, 2015
6. BENGIO, Y; LECUN,Y; HINTON,G ,*Deep Learning*,Canada,2015
7. Deep Machine Learning – A New Frontier in Artificial Intelligence Research – a survey paper by Itamar Arel, Derek C. Rose, and Thomas P. Karnowski. IEEE Computational Intelligence Magazine, 2013.
8. CARLOS ,E. P. *A Pattern Language for Deep Learning*,America,2007
9. GLAUNER, P., *Deep Convolutional Neural Networks for Smile Recognition (MSc Thesis)*, British,2009
10. SONG,H.A.; LEE,S.Y., *Hierarchical Representation Using NMF*. *Neural Information Processing*. Lectures Notes in Computer Sciences. Nature. 278(6266)473–466
11. OLSHAUSEN ,B. A. , *Emergence of simple-cell receptive field properties by learning a sparse code for natural images*. Nature.381 (6583): 607–609.
12. BHAVISHA,T; JOSHI,D, *survey on different steganography techniques, international journal of engineering sciences & research technology*, India, 2015