

تحسين نجاح التلقيح الاصطناعي: الذكاء الاصطناعي والتجزئة الدلالية للتقييم المورفولوجي للأجنة

هديل الحداد، مساعد باحث

د. محمد أرسلان، أستاذ مساعد باحث،

د. عبد العزيز خالد العلي، أستاذ مساعد في هندسة الحاسب،

أ.د. بونوثوراي ناجاراتنام سوجانثان، أستاذ باحث،

كلية الهندسة - جامعة قطر



هديل الحداد

معقولة، ويمكن تقليل خطر مضاعفات الحمل بشكل كبير من خلال اختيار الكيسة الأريمية الأكثر قابلية للحياة لنقلها للرحم.

إن الهدف من هذا البحث هو تحسين طريقة اختيار الأجنة من خلال دمج الذكاء الاصطناعي للتحليل المورفولوجي، حيث سيعمل المخطط الذكي على تقليل الخطأ البشري وتوفير رؤية مورفومترية أسرع لمكونات الجنين المختلفة.

الحل المقترح:

يستخدم الذكاء الاصطناعي بشكل متزايد في شتى القطاعات، بما في ذلك المجال الطبي لتقديم حلول مبتكرة. كما أن التجزئة الدلالية هي فرع من التعلّم العميق تتعامل مع الصور من خلال توفير تسميات على مستوى وحدات البكسل (pixel) لكل وحدة (pixel) في الصورة. هذا النهج مناسب بشكل خاص

يُعرّف العُقْمُ بعدم القدرة على تحقيق الحمل بعد عام من الاتصال الجنسي غير المحمي، وهو يُمثل مصدر قلق صحي متزايد على المستوى العالمي، ووفقاً لمنظمة الصحة العالمية (WHO)، فإن ما يقرب من 17.5% من السكان البالغين في جميع أنحاء العالم سيعانون من العُقْم في مرحلة ما من حياتهم. هذا يُسلط الضوء على أهمية معالجة العُقْم واستكشاف حلول فعّالة. من بين مختلف تقنيات الإنجاب المساعدة (ART)، يبرز التلقيح الاصطناعي (IVF) كخيار رائد لمعالجة العُقْم. يتضمن التلقيح الاصطناعي إخصاب البويضات بالحيوانات المنوية خارج الجسم في بيئة معملية خاضعة للرقابة. يتم استزراع الأجنة حتى تصل إلى مرحلة الكيسة الأريمية (البويضة المخصبة) (Blastocyst) قبل نقلها مرة أخرى إلى الرحم. على الرغم من فعاليته، يمكن أن يكون علاج التلقيح الاصطناعي عبئاً مالياً للعديد من الأزواج، خاصة بالنظر إلى أنه قد تكون هناك حاجة إلى محاولات متعددة لتحقيق حمل ناجح.


التحدّي الآخر هو أن إجراءات التلقيح الاصطناعي تنطوي على نقل أجنة متعددة لزيادة فرص الحمل. ومع ذلك، فقد أدت هذه الممارسة إلى ارتفاع معدل الحمل المتعدد، والذي يأتي مع زيادة المخاطر لكل من الأمهات والأطفال. وفي حالات الحمل المتعددة تُعد مضاعفات الحمل مثل الولادة المبكرة وانخفاض الوزن عند الولادة أكثر شيوعاً.

الهدف:

لخفض نسبة المخاطر المرتبطة بالحمل المُتعدد، تُشير الأبحاث الحديثة إلى التحول نحو نقل كيسة أريمية واحدة قابلة للحياة خلال إجراءات التلقيح الاصطناعي، حيث يُقلل هذا النهج من احتمالية الحمل المُتعدد مع الحفاظ على معدلات نجاح

من اليمين: الأستاذ الدكتور بونوثوراي ناجاراتنام سوجاثان، والدكتور عبد العزيز العلي، والدكتور محمد أرسلان.





الشكل (2): بنية شبكة التصنيف التقليدية.

للسبكة يطابق حجم الصورة الأصلي.

- إضافة طبقة تصنيف وحدات البكسل إلى الشبكة بالتزامن مع دالة تقييم الضعف مناسبة لمهام التجزئة الدلالية.
- بعد تجربة العديد من الشبكات والبُنى مثل VGG16 و-Shuffle-Net، كانت الشبكة المقترحة لهذه المهمة هي DarkNet-53. استند هذا الاختيار إلى الأسباب التالية:
- تُستخدم بشكلٍ شائع في اكتشاف الأشياء، مما أثبت ملاءمتها لمهام التجزئة الدلالية مثل تجزئة مكُونات الكيسة الأريمية.
- استخدام اتصالات التخطي المتبقية، التي تحافظ على المعلومات خلال طبقات الشبكة وتساعد على تجنب مشكلة تلاشي التدرج أثناء التدريب.
- عدم استخدام الشبكة لطبقات التجميع، مما يُمكن أن يساعد في الحفاظ على المعلومات المكانية ومنع فقدان التفاصيل أثناء استخراج الخواص.
- استخدام دالة Leaky ReLU كعملية تنشيط في الوحدات العصبونية (Neuron unit)، مما يساعد على تجنب فقدان المعلومات من خلال السماح للتدرجات بالانتشار حتى في حال تواجد مدخلات سلبية القيمة، مما يُعزز قدرة الشبكة على التقاط ميزات دقيقة.

تعديلات النموذج:

- بعد القيام بعدة اختبارات وتجارب، كما في الشكل 3، تم إجراء العديد من التعديلات على بنية الشبكة كالتالي:
- تم تغيير حجم الشبكة للتوقف عند حجم خريطة الخواص بحجم 50 × 50، لأن هذا الضبط يساعد في تقليل التعقيد الحسابي إلى جانب الحفاظ على خواص الصور الأساسية.
- تمت إضافة ثلاث طبقات لتكبير العينات إلى الشبكة لاسترداد حجم الصورة الأصلي.

لموضوع هذا البحث لعدة أسباب:

- توفير المساعدة لأخصائي الأجنة لتحليل البنية الداخلية ومكونات الكيسة الأريمية.
- يدل تكوين بعض المكُونات مثل ZP/ICM على أن الأجنة تم تحويلها إلى أكياس أريمية وجاهزة للنقل.
- تساعد التجزئة الدلالية على تحديد كل مكُون من مكُونات الكيسة الأريمية (على مستوى وحدات الصورة، pixels) وتُوفر قناع أو فاصل فردي لكل فئة (ICM/TE/ZP/BL). بعد ذلك، يمكن استخدام هذه الأفعنة لتحليل مورفولوجيا هذه المكُونات.

المنهج:

مجموعة البيانات:

استخدام هذا البحث مجموعة بيانات متاحة للعموم تحتوي على 235 صورة للأكياس الأريمية البشرية مع ملاحظات توضيحية على مستوى وحدات البكسل للأديم الظاهر الغاذي (أحد الطبقات التي تتشكل أثناء التكوين الجنيني المبكر) (Trophectoderm, TE)، والمنطقة الشفافة (Zone Pellucida, ZP)، وكتلة الخلية الداخلية (Inner Cell Mass, ICM)، وجوف الأريمية (Blastocoel, BL) كما في الشكل 1.

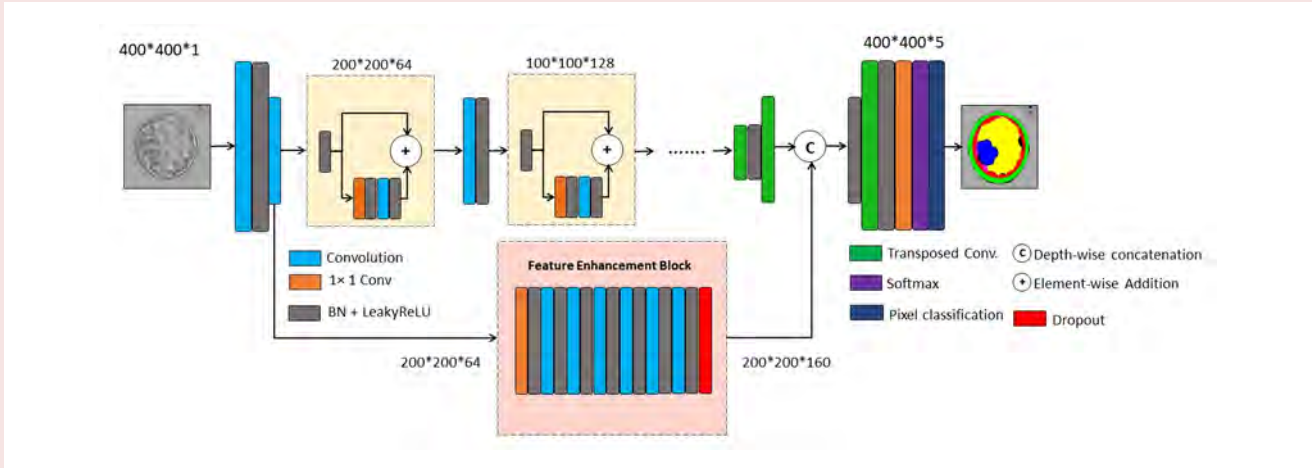


الشكل (1): مكونات الكيسة الأريمية.

تم تقديم هذه التصنيفات من قبل خبير في علم الأجنة، وقد وتم تقسيم مجموعة البيانات إلى مجموعة لتدريب نماذج الذكاء الاصطناعي تضم 85% (200 صورة) ومجموعة اختبار للنموذج المُدرَّب تضم 15% (35 صورة). وبغية الحصول على تدريب كافٍ، تم استخدام طرق تحسين الصورة لإنشاء 6400 صورة محسنة من أصل 200 صورة تدريب عن طريق تحويلات الصورة العامة كالتقليب والدوران وغير ذلك.

التدريب على بناء النموذج:

- يوضح الشكل 2 مثالاً لشبكة التصنيف التقليدية، ويضمن النهج المتبع تحويل نموذج الذكاء الاصطناعي من شبكة تصنيف إلى شبكة تجزئة دلالية من خلال الخطوات التالية:
- إزالة الطبقات المتصلة بالكامل للتكئف مع طبيعة نموذج التجزئة الدلالية.
- إضافة طبقة تكبير عينات والتأكد من أن الحجم الخارجي



الشكل (3): بنية الشبكة المظلمة (Darknet) المعدلة.

في الختام، رغم عرض هذا البحث رؤى واعدة، مازالت هناك أهمية لإجراء المزيد من التجارب المكثفة للتحقق من صحة هذه النتائج بشكل قاطع. وفي المستقبل، سيوفر التعاون مع مؤسسات الرعاية الصحية في قطر فرصة عظيمة للحصول على مجموعة بيانات أكبر وأكثر شمولاً، حيث تُعد هذه الخطوة مهمة لضمان موثوقية وفعالية نهج الحل المقترح في هذا البحث.

جدول (1): مقارنة دقة تصنيف نموذج الذكاء الاصطناعي المقترح في البحث مع المقترحات السابقة.

Method	TE	ZP	ICM	BL	BG	Avg
VGG16	0.709	0.810	0.827	0.861	0.951	0.831
VGG16 with skip	0.758	0.827	0.809	0.874	0.954	0.844
ShuffleNet	0.780	0.819	0.856	0.877	0.951	0.857
(ShuffleNet with skip (Two depth encoder	0.779	0.848	0.861	0.884	0.955	0.865
(ShuffleNet with skip (1 residual, 1 skip	0.790	0.841	0.862	0.884	0.951	0.866
ShuffleNet with FBB	0.792	0.836	0.869	0.887	0.951	0.867
DarkNet	0.783	0.845	0.849	0.880	0.955	0.862
Darknet with FBB	0.808	0.855	0.876	0.900	0.960	0.880

إضافة كتلة معزز الميزة (FBB)، وتم تصميمها لاسترداد المعلومات التي قد تضيع من خلال طبقات أخذ العينات السفلية وذلك عن طريق استخدام سلسلة من الطبقات التلافيفية دون أي طبقة تجميع. وهذه الآلية تعزز قدرة الشبكة على التقاط التفاصيل المعقدة وتحسين دقة التصنيف.

مقاييس التقييم:

مقياس التقييم المستخدم هو مؤشر جاكارد (J) مع وحدات البكسل الإيجابية الحقيقية (TP) والسالبة الكاذبة (FN) والإيجابية الكاذبة (FP).


$$\text{مؤشر جاكارد (IoU)} = \frac{TP}{TP+FN+FP}$$

النتائج والاستنتاج:

تتفوق الشبكة المظلمة Darknet على الشبكات المذكورة حيث تتميز بدقة 87.7% وأدى استخدام Leaky ReLU كوظيفة تنشيط إلى تحسين الأداء من خلال التقاط الميزات المعقدة بشكل فعال. بالإضافة إلى ذلك، فإن إضافة كتلة ملصق الخاصة (FBB) إلى الشبكة يعزز النتائج ويسهل الكشف الدقيق عن الفئات الثانوية.

الجدول رقم 1 يوضح مدى دقة تصنيفات نموذج الذكاء الاصطناعي المقترح ويقارن ذلك بالطرق الأخرى الشائعة في هذا المجال، حيث تعتبر الأرقام الأقرب للرقم 1 أعلى دقة من الأرقام الأقرب للصفر.

النتائج المرئية:



الشكل (4): النتائج المرئية (مقارنة بين نتائج تصنيفات خبير أجنة ونتاج تصنيفات نموذج الذكاء الاصطناعي).

يوضح الشكل 4 أمثلة مقارنة بين صور المصدر ونتاج تصنيفات خبير أجنة، وكذلك ناتج تصنيفات نموذج الذكاء الاصطناعي حيث دقة تصنيفات نموذج الذكاء الاصطناعي تعتبر مشابهة جداً لخبير الأجنة، وتُمثل الألوان الأحمر والأخضر والأزرق والأصفر TE و ZP و ICM و BL على التوالي.