FRUITS AND VEGETABLE RECOGNITION SYSTEM USING CONVOLUTIONAL NEURAL NETWORKS (CNN) WITH RECIPE SUGGESTIONS

نظام التعرف على الفواكه والخضروات باستخدام الشبكات العصبية التلافيفية (CNN) مع اقتراحات الوصفات

Mohammed A.M.K AL-Aimiri
Master Student at School of Computer Application Lovely Professional University Phagwara, India

Yahya Taha Abdo AL-Ademi
PhD, Scientific Organization for Research and Innovation - Yemen

Scientific Supervisor المشرف العلمي

Abstract: *The rapid advancement in computer vision and deep learning has paved the way for innovative applications in food recognition. This mini report presents a comprehensive approach to developing a Fruits and Vegetable Recognition System using Convolutional Neural Networks (CNNs). The system not only identifies various fruits and vegetables but also provides users with recipe suggestions based on the recognized items. The integration of image processing techniques with a user-friendly interface enhances the cooking experience, promoting healthier eating habits.*

Keywords: *CNN architecture, data augmentation, image preprocessing, model training, recipe suggestion.*

محمد عبدالباسط محمد كامل الأميري
طالب ماجستير في كلية تطبيقات الحاسوب، جامعة لوفلي بروفيشنال، فاغوارا، الهند

د. يحيى طه عبده الأديمي
المنظمة العلمية للبحوث والإبتكارات – الجمهورية اليمنية

الخلاصة : لقد مهد التقدم السريع في مجال الرؤية الحاسوبية والتعلم العميق الطريق لتطبيقات مبتكرة في التعرف على الأطعمة. يقدم هذا التقرير المصغر نهجًا شاملاً لتطوير نظام التعرف على الفواكه والخضروات باستخدام الشبكات العصبية التلافيفية (CNNs). لا يقوم النظام بتحديد الفواكه والخضروات المختلفة فحسب، بل يوفر أيضًا للمستخدمين اقتراحات وصفات بناءً على العناصر المعترف بها. يعمل دمج تقنيات معالجة الصور مع واجهة سهلة الاستخدام على تحسين تجربة الطهي، وتعزيز عادات الأكل الصحية.

الكلمات المفتاحية : هندسة CNN، وزيادة البيانات، ومعالجة الصور مسبقًا، وتدريب النموذج، واقتراح الوصفات.

Introduction

With the increasing emphasis on healthy eating and nutrition, the demand for effective food recognition systems has grown. Recognizing fruits and vegetables can facilitate meal planning, encourage cooking, and promote the consumption of fresh produce. This paper outlines the development of a CNN-based system that identifies fruits and vegetables from images and offers recipe suggestions, thereby enhancing user engagement and culinary creativity.

Results and discussion

A diverse dataset of images of fruits and vegetables was collected from various sources, including online repositories and personal photographs [1-3]. The dataset comprises thousands of labeled images, covering a wide range of produce, ensuring robust model training. Before feeding the images into the CNN, several preprocessing steps were performed:

- Resizing: All images were resized to a uniform dimension (e.g., 128x128 pixels) to ensure consistency.
- Normalization: Pixel values were normalized to the range [0, 1] to facilitate faster convergence during training.
- Augmentation: Data augmentation techniques, such as rotation, flipping, and zooming, were applied to increase dataset diversity and reduce overfitting.

A custom CNN architecture was designed with the following layers:

- Convolutional Layers: Multiple convolutional layers with ReLU activation functions to extract features from images.
- Pooling Layers: Max pooling layers to down-sample the feature maps, reducing dimensionality.
- Fully Connected Layers: Dense layers for classification, with a softmax activation function in the output layer to predict the probabilities of each class.

The model was trained using a portion of the dataset, with 80% allocated for training and 20% for validation. The Adam optimizer was employed, and the categorical cross-entropy loss function was used to evaluate model performance. The training process involved multiple epochs, with early stopping implemented to prevent overfitting. Upon successful identification of fruits and vegetables, the system queries a recipe database to suggest relevant recipes. The database includes a variety of recipes categorized by ingredients. The suggestions are generated based on the recognized items, allowing users to explore different culinary options.

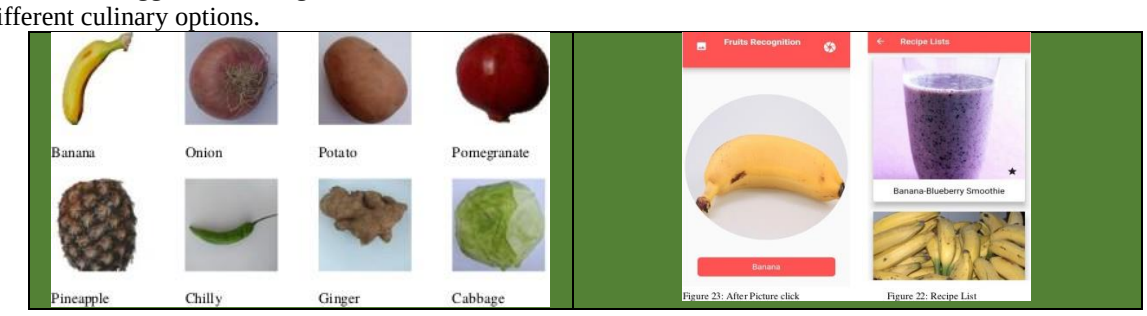

a ***b***

Fig 1- a. Image of the input dataset, b. Program outputs and suggestions

الشكل ١- أ. صورة لمجموعة البيانات المدخلة، ب. مخرجات البرنامج ومقترحاته

The CNN achieved a commendable accuracy of over 90% on the validation dataset. Confusion matrices were analyzed to evaluate the model's performance across different classes, revealing that most fruits and vegetables were correctly identified, with a few exceptions attributed to similarities in appearance. A user-friendly interface was developed, allowing users to upload images or use their device's camera for real-time recognition. The interface displays the identified produce along with suggested recipes, enhancing the user experience. The recipe suggestion engine successfully provided relevant options based on the recognized items. For example, if the system identifies tomatoes, it suggests recipes such as "Tomato Basil Pasta" or "Caprese Salad," promoting the use of fresh ingredients in cooking. The Fruits and Vegetable Recognition System demonstrates the effectiveness of CNNs in food identification tasks. The integration of a recipe suggestion feature adds significant value, encouraging users to engage with their food choices actively. The system can be further enhanced by incorporating additional features, such as nutritional information and cooking tips, to enrich the user experience. Future developments may include expanding the dataset to encompass a broader range of produce and improving the recipe database with user-generated content. Additionally, exploring transfer learning techniques could optimize model performance with fewer data requirements.

Conclusion

This mini report presents a novel Fruits and Vegetable Recognition System utilizing CNNs, coupled with recipe suggestions to inspire healthier cooking habits. The successful implementation of this system highlights the potential of AI and machine learning in the culinary domain, making it easier for users to make informed food choices and explore cooking creatively.

المقدمة

مع التركيز المتزايد على الأكل الصحي والتغذية، تزايد الطلب على أنظمة التعرف الفعّالة على الأطعمة. إن التعرف على الفواكه والخضروات يمكن أن يسهل التخطيط للوجبات، ويشجع على الطهي، ويعزز استهلاك المنتجات الطازجة. تسلط هذه الورقة الضوء على تطوير نظام قائم على شبكة CNN يحدد الفواكه والخضروات من الصور ويقدم اقتراحات لوصفات، وبالتالي يعزز مشاركة المستخدم والإبداع في الطهي.

النتائج والمناقشة

تم جمع مجموعة بيانات متنوعة من صور الفواكه والخضروات من مصادر مختلفة، بما في ذلك مستودعات البيانات عبر الإنترنت والصور الشخصية [1-3]. تتألف مجموعة البيانات من آلاف الصور المصنفة، والتي تغطي مجموعة واسعة من المنتجات، مما يضمن تدريبًا قويًا للنموذج. قبل إدخال الصور في CNN، تم تنفيذ العديد من خطوات المعالجة المسبقة:

• تغيير الحجم: تم تغيير حجم جميع الصور إلى أبعاد موحدة (على سبيل المثال، 128 × 128 بكسل) لضمان الاتساق.

• التطبيع: تم تطبيع قيم البكسل إلى النطاق [0، 1] لتسهيل التقارب بشكل أسرع أثناء التدريب.

• التكبير: تم تطبيق تقنيات تكبير البيانات، مثل الدوران والتقليب والتكبير، لزيادة تنوع مجموعة البيانات والحد من الإفراط في التجهيز.

تم تصميم بنية CNN مخصصة بالطبقات التالية:

• طبقات ملتوية: طبقات ملتوية متعددة مع وظائف تنشيط ReLU لاستخراج الميزات من الصور.

• طبقات التجميع: طبقات التجميع القصوى لتقليل عينات خرائط الميزات، مما يقلل من الأبعاد.

• طبقات متصلة بالكامل: طبقات كثيفة للتصنيف، مع وظيفة تنشيط سوفت ماكس في طبقة الإخراج للتنبؤ باحتمالات كل فئة.

تم تدريب النموذج باستخدام جزء من مجموعة البيانات، مع تخصيص 80% للتدريب و20% للتحقق. تم استخدام مُحسِّن آدم، وتم استخدام دالة فقدان الإنتروبيا المتقاطعة التصنيفية لتقييم أداء النموذج. تضمنت عملية التدريب عصورًا متعددة، مع تنفيذ التوقف المبكر لمنع الإفراط في التجهيز. عند التعرف الناجح على الفواكه والخضروات، يستعلم النظام عن قاعدة بيانات الوصفات لاقتراح وصفات ذات صلة. تتضمن قاعدة البيانات مجموعة متنوعة من الوصفات المصنفة حسب المكونات. يتم إنشاء الاقتراحات بناءً على العناصر المعترف بها، مما يسمح للمستخدمين باستكشاف خيارات الطهي المختلفة.

وقد حققت الشبكة العصبية الاصطناعية دقة جديرة بالثناء تزيد عن 90% في مجموعة بيانات التحقق. وتم تحليل مصفوفات الارتباك لتقييم أداء النموذج عبر فئات مختلفة، وكشفت النتائج أن معظم الفواكه والخضروات تم التعرف عليها بشكل صحيح، مع بعض الاستثناءات المنسوبة إلى أوجه التشابه في المظهر. وتم تطوير واجهة سهلة الاستخدام، تسمح للمستخدمين بتحميل الصور أو استخدام كاميرا أجهزتهم للتعرف في الوقت الفعلي. وتعرض الواجهة المنتجات التي تم التعرف عليها إلى جانب الوصفات المقترحة، مما يعزز تجربة المستخدم. وقد قدم محرك اقتراح الوصفات بنجاح خيارات ذات صلة بناءً على العناصر التي تم التعرف عليها. على سبيل المثال، إذا حدد النظام الطماطم، فإنه يقترح وصفات مثل "معكرونة الطماطم والريحان" أو "سلطة كابريزي"، مما يعزز استخدام المكونات الطازجة في الطهي. ويوضح نظام التعرف على الفواكه والخضروات فعالية الشبكات العصبية الاصطناعية في مهام التعرف على الطعام. ويضيف دمج ميزة اقتراح الوصفات قيمة كبيرة، مما يشجع المستخدمين على المشاركة في اختياراتهم الغذائية بنشاط. ويمكن تحسين النظام بشكل أكبر من خلال دمج ميزات إضافية، مثل المعلومات الغذائية ونصائح الطهي، لإثراء تجربة المستخدم. قد تتضمن التطورات المستقبلية توسيع مجموعة البيانات لتشمل مجموعة أوسع من المنتجات وتحسين قاعدة بيانات الوصفات باستخدام المحتوى الذي ينشئه المستخدم. بالإضافة إلى ذلك، قد يؤدي استكشاف تقنيات التعلم بالنقل إلى تحسين أداء النموذج مع متطلبات بيانات أقل.

الخاتمة

يقدم هذا التقرير المصغر نظامًا جديدًا للتعرف على الفواكه والخضروات باستخدام شبكات CNN، إلى جانب اقتراحات الوصفات لإلهام عادات الطهي الصحية. يسلط التنفيذ الناجح لهذا النظام الضوء على إمكانات الذكاء الاصطناعي والتعلم الآلي في المجال الطهوي، مما يسهل على المستخدمين اتخاذ خيارات غذائية مستنيرة واستكشاف الطهي بشكل إبداعي.

Literature المراجع والمصادر

1. LeCun, Y., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.
2. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems, 25.
3. Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.