

TÍCH HỢP ROBOT DẪN HƯỚNG THỊ GIÁC ĐAN ĐẢO NGƯỢC TRONG TỰ ĐỘNG HÓA SẢN XUẤT DỆT MAY

INTEGRATING VISION-GUIDED ROBOTICS FOR REVERSE KNITTING IN AUTOMATED TEXTILE MANUFACTURING

ThS. Nguyễn Thị Hòa

Khoa Dệt may Thời trang, Trường Đại học Kinh tế - Kỹ thuật Công nghiệp

Email: nthoa@uneti.edu.vn

TÓM TẮT

Đan dệt là một công đoạn cốt lõi của ngành dệt may nhưng vẫn khó tự động hóa, đặc biệt trong việc chuyển đổi thiết kế vải thành các chỉ dẫn đan có thể thực thi bằng máy. Nghiên cứu này đề xuất một pipeline đan đảo ngược hai giai đoạn, định hướng ứng dụng robot và cơ điện tử, nhằm tích hợp thị giác máy với hệ thống đan tự động.

Pipeline gồm giai đoạn nhận dạng nhãn mũi đan mặt trước từ ảnh vải và giai đoạn suy luận nhãn đầy đủ mang tính cấu trúc, đảm bảo khả năng đan được trên máy đan phẳng điều khiển số. Thiết kế mô-đun cho phép hệ thống dễ tích hợp vào dây chuyền sản xuất và mở rộng cho các kịch bản công nghiệp.

Phương pháp được đánh giá trên cả mẫu sợi đơn và đa sợi, cho thấy khả năng thích ứng tốt với sự đa dạng cấu trúc và vật liệu. Các thách thức trong tự động hóa dệt may như mất cân bằng nhãn, mũi đan hiếm và yêu cầu kiểm soát chi tiết được giải quyết thông qua các kiến trúc học sâu phù hợp với đặc thù cơ học của quá trình đan.

Nghiên cứu đặt nền móng cho các hệ thống robot đan dệt tự động hoàn toàn, hướng tới sản xuất dệt may thông minh, linh hoạt và tùy biến cao.

Từ khoá: Đan dệt tự động; Học sâu; Mạng đối sinh; Mạng nơ-ron dư; Kỹ thuật vải.

ABSTRACT

Knitting is a core process in textile manufacturing, yet remains difficult to automate, particularly in translating fabric designs into machine-executable knitting instructions. This study proposes a two-stage reverse knitting pipeline, oriented toward robotic and mechatronic applications, to integrate machine vision with automated knitting systems.

The pipeline consists of a front-side stitch label recognition stage from fabric images and a structural inference stage that reconstructs complete knitting instructions, ensuring knittability on computer-controlled flat knitting machines. Its modular design enables seamless integration into

automated production lines and supports scalability across industrial scenarios.

The proposed method is evaluated on both single-yarn and multi-yarn fabric samples, demonstrating robustness to structural and material variability. Key challenges in robotic textile automation, including label imbalance, underrepresented stitch types, and fine-grained structural control, are addressed through deep learning architectures tailored to the mechanical characteristics of the knitting process.

This work lays the foundation for fully automated robotic knitting systems, enabling intelligent, flexible, and customizable textile manufacturing.

Keywords: *Automated knitting; Deep learning; GAN; ResNet; Fabric engineering.*

1. ĐẶT VẤN ĐỀ

Nghiên cứu này nhằm phát triển một quy trình học sâu hai giai đoạn cho bài toán đảo ngược, chuyển đổi ảnh vải đan thực thành các nhãn mũi đan có thể sử dụng cho máy đan. Quy trình gồm giai đoạn sinh để dự đoán nhãn mặt trước và giai đoạn suy luận để tạo nhãn đầy đủ. Mục tiêu là nâng cao độ chính xác dự đoán trên các cấu trúc sợi đa dạng, giải quyết thách thức của mẫu sợi đơn (sj) và đa sợi (mj), đồng thời đánh giá khả năng xử lý dữ liệu mất cân bằng và khả năng khái quát hóa trong thực tế.

Nghiên cứu tập trung vào ba vấn đề chính: (i) thiết kế hiệu quả quy trình học sâu hai giai đoạn cho chuyển đổi ảnh vải–nhãn mũi đan; (ii) tối ưu hóa hiệu năng thông qua các lựa chọn thiết kế như hàm mất mát, huấn luyện theo loại sợi và kiến trúc mô hình; (iii) đánh giá khả năng thích ứng của quy trình với các ràng buộc thực tế như dữ liệu mất cân bằng và các loại sợi chưa biết.

Các nghiên cứu ban đầu, tiêu biểu là Kaspar và cộng sự [2], đề xuất kiến trúc Refiner+Img2prog dựa trên SimGAN [3] để dự đoán nhãn mặt trước từ ảnh thực, nhưng còn hạn chế do mất cân bằng dữ liệu và bài toán


một–nhiều, vốn bị khuếch đại bởi các chiến lược MIL [2]. Các hướng tiếp cận gần đây tập trung vào hàm mất mát chặt chẽ hơn nhằm cải thiện độ chính xác. Các nghiên cứu của Trunz và cộng sự [4], Melnyk [5] mở rộng các phương pháp GAN [6] để mô hình hóa đặc tính sợi và phong cách vải; CNN và LSTM [7] được dùng để nắm bắt quan hệ không gian và phụ thuộc theo hàng. Tuy nhiên, các công trình này chủ yếu phục vụ tạo sinh mũi đan.

Ở giai đoạn suy luận, logic giữa các mũi đan là yếu tố then chốt. Các mô hình lưới mũi đan [8, 9], kiến trúc dư [10] và các phương pháp từ mô hình 3D sang tập lệnh đan [11] đã được đề xuất, song vẫn tồn tại các hạn chế về đại diện nhãn hiếm, khả năng mở rộng cho đa sợi và hiệu quả tính toán [2, 4, 5, 11]. Do đó, nghiên cứu này ưu tiên CNN dư, UNet và CNN đa tầng để khai thác phụ thuộc cục bộ giữa các mũi đan, sử dụng kernel 3×3 nhằm đảm bảo tính ổn định và hiệu quả tính toán.

2. THU THẬP VÀ CHUẨN BỊ DỮ LIỆU

Quy trình thu thập và chuẩn bị dữ liệu bao gồm việc xây dựng dữ liệu chuẩn (ground truth) và xác định các khái niệm liên quan đến sợi và mũi đan. Như minh họa trong Hình 1, 

dữ liệu chuẩn gồm bốn thành phần: nhãn đầy đủ (complete label) do chuyên gia thiết kế và làm nền tảng; nhãn mặt trước (front label) được suy ra thông qua ánh xạ; ảnh dựng (rendering image) được tạo từ nhãn đầy đủ; và ảnh thực (real image) thu được bằng cách đan nhãn đầy đủ thành vải vật lý.




Hình 1. Quy trình xử lý dữ liệu

Các thành phần dữ liệu được xây dựng có hệ thống thông qua ánh xạ nhãn, dựng hình và đan mẫu thực. Bộ dữ liệu được phân loại theo loại sợi và mẫu mũi đan, bao gồm sợi đơn (sj) và đa sợi (mj), trong đó mj được chia thành 2j, 3j và 4j. Do hạn chế sản xuất, hầu hết cấu trúc vải sử dụng ít hơn bốn màu sợi. Mỗi mẫu dữ liệu tương ứng với một lưới mũi đan 20×20 , trong đó các mũi như FK, BK, ... phản ánh chi tiết cấu trúc vải.

Nhằm khắc phục hạn chế về số lượng ảnh thực trong bộ dữ liệu của Kaspar (1043 ảnh mặt trước), nghiên cứu sử dụng tăng cường dữ liệu bằng ảnh chuyển đổi (Hình 2). Cả ảnh dựng và ảnh chuyển đổi đều được tạo từ nhãn đầy đủ bằng phần mềm m1plus của Stoll [1]. Các ảnh chuyển đổi đóng vai trò thay thế ảnh thực, cho phép xây dựng bộ dữ liệu lớn và cân bằng hơn, từ đó nâng cao độ tin cậy trong huấn luyện và đánh giá mô hình.

Nhãn đầy đủ không được cung cấp trực tiếp ở dạng thô mà được suy ra từ nhãn đầy đủ có màu thông qua gộp nhãn (label aggregation). Quá trình này giữ lại thông tin cấu trúc mũi đan và loại bỏ thông tin màu. Cách tiếp cận này giúp đơn giản hóa bài toán bằng cách tập trung vào cấu trúc mũi đan, không xét đến nhận dạng màu sắc.

Nhận dạng màu sợi không nằm trong phạm vi nghiên cứu; trọng tâm của nghiên cứu là xác định cấu trúc mũi đan phục vụ tạo chỉ dẫn đan.




Hình 2. So sánh giữa ảnh chuyển tiếp và ảnh thực

2.1. Thu nhận ảnh

Ảnh dựng được tổng hợp bằng phần mềm m1plus của Stoll [1], mô phỏng cấu trúc vải ảo từ nhãn đầy đủ. Sau khi nhập nhãn, m1plus tạo ra các ảnh dựng tương ứng, đóng vai trò là đầu ra trung gian, giúp thu hẹp khoảng cách giữa thiết kế ảo và dữ liệu đan thực tế.


Ảnh thực được tạo bằng máy đan phẳng điều khiển số của Stoll, lập trình trực tiếp từ đầu ra của m1plus. Để tăng hiệu quả, nhiều mẫu được đan trên cùng một tấm vải (Hình 3), sau đó các vùng quan tâm (ROI) được đánh dấu thủ công để tách từng hoa văn. Ảnh được chụp bằng iPhone 16 Pro Max ở chế độ RAWMAX, trong hộp chụp kiểm soát ánh sáng, nhằm đảm bảo chất lượng cao cho các bước xử lý tiếp theo.



Hình 3. Tấm vải đan vật lý

2.2. Phân bố loại sợi và mũi đan

Bộ dữ liệu gồm 4.950 mẫu (Hình 4), bao gồm 3.000 mẫu sợi đơn (sj) và 1.950 mẫu đa sợi (mj). Các mẫu sj được phân bố đều trên 10 nhóm mũi đan (Hem, Move1, Miss, Cable1, Links2, Move2, Cable2, Mesh, Tuck, Links1), với khoảng 300 mẫu mỗi nhóm. Mặc dù có bộ dữ liệu sj lớn hơn (12.392 mẫu) từ Kaspar và cộng sự [2], số mẫu sj được giới hạn để đảm bảo cân bằng với mj, hỗ trợ huấn luyện hiệu quả.



Hình 4. Phân bố các loại sợi

Phân bố nhẵn cho thấy mất cân bằng đáng kể (Hình 5). Với nhẵn mặt trước, FK

chiếm khoảng 75%, trong khi các nhẵn khác bị thiếu đại diện. Tương tự, ở nhẵn đầy đủ, FK chiếm 46,5%, tiếp theo là FK, MAK (27,1%), còn lại có tần suất thấp. Sự mất cân bằng này phản ánh đặc thù dữ liệu dệt may thực tế và cho thấy sự cần thiết của các chiến lược huấn luyện mạnh mẽ để giảm ảnh hưởng tiêu cực đến hiệu năng mô hình.



(a)



(b)

Hình 5. Phân bố các mũi đan cho nhẵn mặt trước (a) và nhẵn đầy đủ (b)

3. THIẾT LẬP THÍ NGHIỆM VÀ KẾT QUẢ

Thí nghiệm được thực hiện trên NVIDIA RTX 2070, môi trường Windows 11 + WSL2 (Ubuntu 18.04), sử dụng TensorFlow 1.11, CUDA 9.0 và cuDNN 7.1.

Bảng 1. Kết quả của các mô hình được sử dụng trong giai đoạn sinh

Mô hình	Kích thước mẫu	Số lượng tham số*	Thời gian (h)	Chỉ số F1
RFI với cấu trúc phức (complex), tham số $\alpha = 0,5$.	12,392	2,934,605	6.50	90.2%
RFINet (không transfer learning, không data augmentation, nhẵn mũi mới).	12,392	2,934,398	5.00	97.3%
RFINet nhẵn mặt trước, transfer learning, MIL, 160k mẫu.	4950	2,934,398	3.00	82.1%
RFINet (nhẵn mặt trước, transfer learning, 160k mẫu).	4950	2,934,398	3.00	83.1%

Kết quả (Bảng 1) cho thấy việc giảm không gian nhân xuống 14 nhân mặt trước, kết hợp ánh xạ trực tiếp ảnh thực-ảnh dựng và tăng cường dữ liệu bằng transfer images, giúp nâng F1-score từ 90,2% lên 97,3% so với mô hình cơ sở.

Trên tập dữ liệu chọn lọc 4.950 mẫu (sj+mj), mô hình RFINet_front_xferln_160k (không MIL) đạt F1-score 83,1%, cao hơn phiên bản có MIL (82,1%), đặc biệt cải thiện dự đoán các nhân hiếm. Do đó, mô hình này được chọn cho giai đoạn sinh.

4. KẾT LUẬN

Nghiên cứu này đã giải quyết các thách thức cốt lõi của bài toán đan ngược (reverse knitting) thông qua việc đề xuất một pipeline hai giai đoạn dạng mô-đun, trong đó tách biệt rõ ràng giữa sinh nhân mặt trước và suy luận nhân đầy đủ. Pipeline khai thác hiệu quả các mô hình CNN dư, cho phép nắm bắt các phụ thuộc không gian giữa các mũi đan và sinh ra các chỉ dẫn đan có độ chính xác cao. Kết quả đạt F1-score 83,1% trong Kịch bản 1 và lên tới 97,0% trong Kịch bản 3, trong đó khả năng hiệu chỉnh lỗi của giai đoạn suy luận đóng vai trò then chốt trong việc đảm bảo tính khả thi (knittable) của đầu ra.

Trong tương lai, cần mở rộng tập dữ liệu, đặc biệt là các mẫu đa sợi (multi-yarn); giải quyết bài toán mất cân bằng nhân; và áp dụng các kỹ thuật tăng cường dữ liệu như xoay ảnh hoặc điều chỉnh độ sáng.

Hiện tại, pipeline vẫn bị giới hạn bởi kích thước đầu vào cố định (160×160) và lưới mũi đan 20×20. Do đó, các hướng nghiên cứu tiếp theo có thể tập trung vào việc xử lý kích thước biến thiên thông qua các mô hình phát hiện đối tượng tự động phát hiện và gán nhãn

từng mũi đan. Những hướng phát triển này mở đường cho các hệ thống sản xuất dệt may tự động và tùy biến cao, đồng thời tạo tiền đề mở rộng sang các quy trình liên miền như dệt thoi và thêu. ❖

Ngày nhận bài: **16/01/2026**

Ngày phản biện: **28/01/2026**

Tài liệu tham khảo:

- [1]. Bohm, G.; Suteu, M.D.; Doble, L., “Study on knitting with 3D drawings using the technology offered by Stoll”. Fascicle Text. Leatherwork, 23, 5-9, 2022.
- [2]. Kaspar, A.; Oh, T.-H.; Makatura, L.; Kellnhofer, P.; Matusik, W., “Neural inverse knitting: From images to manufacturing instructions”. In Proceedings of the 36th International Conference on Machine Learning, Long Beach, CA, USA, pp 3272-3281, 9-15 June 2019.
- [3]. Shrivastava, A.; Pfister, T.; Tuzel, O.; Susskind, J.; Wang, W.; Webb, R., “Learning from simulated and unsupervised images through adversarial training”. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, pp 2107-2116, 21-26 July 2017.
- [4]. Trunz, E.; Klein, J.; Müller, J.; Bode, L.; Sarlette, R.; Weinmann, M.; Klein, R., “Neural inverse procedural modeling of knitting yarns from images”. Comput. Graph, 118, 161-172, 2024.
- [5]. Melnyk, V.E., “Punch card patterns designed with GAN”. In Proceedings of the 2021 DigitalFUTURES; Springer: Singapore; pp 83-94, 2022.
- [6]. Mao, X.; Li, Q.; Xie, H.; Lau, R.Y.K.; Wang, Z.; Smolley, S.P., “Least squares generative adversarial networks”. In Proceedings of the IEEE International Conference on Computer Vision, Venice, Italy, pp 2794-2802, 22-29 October 2017.
- [7]. Scheidt, F.; Ou, J.; Ishii, H.; Meisen, T., “deepKnit: Learning-based generation of machine knitting code”. Procedia Manuf, 51, 485-492, 2020.
- [8]. Wu, K.; Swan, H.; Yuksel, C., “Knittable stitch meshes”. ACM Trans. Graph, 37, 121:1-121:14, 2018.
- [9]. Wu, K.; Gao, X.; Ferguson, Z.; Panozzo, D.; Yuksel, C., “Stitch meshing”. ACM Trans. Graph, 37, 130:1-130:14, 2018.
- [10]. He, K.; Zhang, X.; Ren, S.; Sun, J., “Deep residual learning for image recognition”. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, pp 770-778, 37-30 June 2016.
- [11]. Narayanan, V.; Albaugh, L.; Hodgins, J.; Coros, S.; McCann, J., “Automatic knitting of 3D meshes”. ACM Trans. Graph, 37, 109:1-109:14, 2018.