

بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی با استفاده از الگوریتم‌های تکاملی و شبکه‌های عصبی گرافی

مریم مسلمی

کارشناسی طراحی پوشاک، موسسه آموزش عالی هنر شیراز

m.moslemi90@gmail.com

چکیده

صنعت نساجی و پوشاک با چالش‌های چشم‌افزایی در زمینه بهره‌وری منابع و کاهش ضایعات مواجه است. هزینه مواد اولیه در این صنعت بین ۵۰ تا ۷۵ درصد کل هزینه‌های تولید را تشکیل می‌دهد و ضایعات ناشی از برش و دوخت می‌تواند بین ۱۰ تا ۱۵ درصد مواد اولیه را هدر دهد. این پژوهش به بررسی کاربرد الگوریتم‌های تکاملی و شبکه‌های عصبی گرافی در بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی می‌پردازد. روش پیشنهادی شامل یک چارچوب دو مرحله‌ای است: در مرحله اول، مسئله گروه‌بندی قطعات با استفاده از شبکه‌های عصبی گرافی و یادگیری تقویتی حل می‌شود و در مرحله دوم، چیدمان بهینه با استفاده از الگوریتم‌های تکاملی انجام می‌گیرد. نتایج پیاده‌سازی بر روی داده‌های واقعی صنعتی نشان می‌دهد که رویکرد ترکیبی ارائه شده می‌تواند زمان محاسبات را تا ۴۸ درصد کاهش داده و ضایعات مواد را تا ۷۰ درصد نسبت به روش‌های سنتی بهبود بخشد. همچنین، این روش با در نظر گرفتن عدم قطعیت‌های ناشی از تغییر شکل پارچه در فرآیند برش، راهکارهای مقاوم‌تری را ارائه می‌دهد که در محیط‌های تولیدی واقعی کاربردپذیری بالایی دارند.

واژگان کلیدی: بهینه‌سازی الگوی دوخت، کاهش ضایعات نساجی، الگوریتم‌های تکاملی، شبکه‌های عصبی گرافی، یادگیری تقویتی، مسئله برش و بسته‌بندی

۱. مقدمه

صنعت نساجی و پوشاک به عنوان یکی از بزرگترین صنایع تولیدی جهان، سهم قابل توجهی در اقتصاد جهانی دارد. با این حال، این صنعت با چالش‌های جدی در زمینه بهره‌وری منابع و پایداری زیست‌محیطی مواجه است. هزینه مواد اولیه در تولید پوشاک بین ۵۰ تا ۷۵ درصد کل هزینه‌های تولید را تشکیل می‌دهد و ضایعات ناشی از فرآیندهای برش و دوخت می‌تواند بین ۱۰ تا ۱۵ درصد مواد اولیه را هدر دهد (al et Wong, ۲۰۱۳; Yüksel, & Ünal, ۲۰۲۰). با توجه به افزایش قیمت مواد اولیه و فشارهای زیست‌محیطی برای کاهش پسماند، بهینه‌سازی مصرف پارچه به یکی از اولویت‌های اصلی این صنعت تبدیل شده است.

مسئله برنامه‌ریزی الگوی برش (COP - Planning Order Cut) یکی از چالش‌برانگیزترین مسائل بهینه‌سازی در صنعت نساجی محسوب می‌شود. این مسئله شامل تعیین تعداد لایه‌های پارچه، چیدمان قطعات الگو بر روی پارچه و برنامه‌ریزی عملیات برش به گونه‌ای است که مصرف مواد اولیه، زمان و هزینه‌های تولید به حداقل برسد (al et Jacobs-Blecha, ۱۹۹۸; al et Tsao, ۲۰۲۲). ماهیت این مسئله به دلیل شکل‌های نامنظم قطعات پوشاک، محدودیت‌های تکنولوژیکی دستگاه‌های برش و تنوع سایزها و مدل‌ها، به عنوان یک مسئله NP-hard طبقه‌بندی می‌شود که حل آن با روش‌های دقیق ریاضی در ابعاد واقعی عملاً غیرممکن است (al et Nascimento, ۲۰۱۰; al et Shang, ۲۰۱۹).

در سال‌های اخیر، روش‌های محاسبات نرم و هوش مصنوعی توجه زیادی را در حوزه بهینه‌سازی فرآیندهای تولید نساجی به خود جلب کرده‌اند. الگوریتم‌های تکاملی (EA - Algorithms Evolutionary) با الهام از فرآیند انتخاب طبیعی، توانایی بالایی در یافتن جواب‌های نزدیک به بهینه برای مسائل پیچیده بهینه‌سازی دارند (Schwefel, & Bäck, ۱۹۹۸; Porter, ۱۹۹۳). از سوی دیگر، شبکه‌های عصبی عمیق و به ویژه شبکه‌های عصبی گرافی (GNN - Graph Neural Networks) به دلیل توانایی در مدل‌سازی روابط پیچیده بین اشیاء و یادگیری ویژگی‌های ساختاری، رویکردهای جدیدی را برای حل مسائل چیدمان و برش ارائه داده‌اند (al et Abdou, ۲۰۲۴; Lallier, ۲۰۲۲).

با وجود پیشرفت‌های قابل توجه در هر یک از این حوزه‌ها، همچنان شکاف‌های پژوهشی مهمی در زمینه ترکیب این روش‌ها و کاربرد آن‌ها در بهینه‌سازی الگوی دوخت وجود دارد. به ویژه، مسئله گروه‌بندی قطعات قبل از مرحله چیدمان که تأثیر مستقیمی بر کاهش ضایعات دارد، کمتر مورد توجه قرار گرفته است (al et Abdou, ۲۰۲۴). همچنین، در نظر گرفتن همزمان عدم قطعیت‌های ناشی از تغییر شکل پارچه و بهینه‌سازی مسیر برش، از چالش‌های اساسی در محیط‌های تولیدی واقعی است که نیازمند رویکردهای یکپارچه می‌باشد (al et Silva, ۲۰۱۹; al et Júnior Neuenfeldt, ۲۰۲۳).

این پژوهش با هدف پر کردن این شکاف‌ها، یک چارچوب جامع برای بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی ارائه می‌دهد که از ترکیب الگوریتم‌های تکاملی و شبکه‌های عصبی گرافی استفاده می‌کند. سوالات اصلی پژوهش عبارتند از: (۱) چگونه می‌توان از شبکه‌های عصبی گرافی برای حل مسئله گروه‌بندی قطعات در الگوی دوخت استفاده کرد؟ (۲) چه تأثیری بر کارایی و کاهش ضایعات دارد؟ (۳) چگونه می‌توان عدم قطعیت‌های ناشی از تغییر شکل پارچه را در مدل‌سازی گنجانده؟

ساختار مقاله به این صورت است: در بخش ۲، مروری بر پیشینه پژوهش انجام می‌شود. بخش ۳ به تشریح مبانی نظری و مفاهیم کلیدی می‌پردازد. در بخش ۴، چارچوب پیشنهادی ارائه می‌شود. بخش ۵ شامل پیاده‌سازی و نتایج تجربی است و در بخش ۶ نتیجه‌گیری و پیشنهادات برای پژوهش‌های آینده ارائه می‌گردد.

۲. مروری بر پیشینه پژوهش

۲.۱. مسئله برنامه‌ریزی الگوی برش در صنعت نساجی

مسئله برنامه‌ریزی الگوی برش (COP) به عنوان یکی از چالش‌های اساسی در صنعت نساجی، از دهه‌ها پیش مورد توجه محققان بوده است. این مسئله شامل تعیین تعداد لایه‌های پارچه، نحوه چیدمان قطعات الگو و برنامه‌ریزی عملیات برش به گونه‌ای است که هزینه‌های تولید به حداقل برسد (al et Jacobs-Blecha, ۱۹۹۸; Yüksel, & Ünal, ۲۰۲۰). هزینه پارچه به عنوان بزرگترین جزء هزینه‌های تولید، اهمیت بهینه‌سازی مصرف آن را دوچندان می‌کند (al et Wong, ۲۰۱۳).

مطالعات اولیه در این حوزه عمدتاً بر روی مدل‌سازی ریاضی و استفاده از روش‌های دقیق مانند برنامه‌ریزی خطی عدد صحیح متمرکز بود (Vandebroek, & Degraeve, ۱۹۹۸). با این حال، به دلیل ماهیت NP-hard مسئله، این روش‌ها در مواجهه با ابعاد واقعی صنعتی با محدودیت‌های جدی مواجه شدند (al et Nascimento, ۲۰۱۰). به عنوان مثال، Vandebroek و Degraeve (۱۹۹۸) یک مدل برنامه‌ریزی عدد صحیح مختلط برای حل مسئله چیدمان در صنعت مد ارائه دادند، اما این مدل تنها برای مسائل کوچک قابل حل بود.

با افزایش پیچیدگی مسائل و رشد ابعاد داده‌ها، روش‌های ابتکاری و فراابتکاری جایگاه ویژه‌ای در این حوزه پیدا کردند. Shang و همکاران (۲۰۱۹) یک الگوریتم ابتکاری برای مسئله پخش و برش پارچه در کارخانه‌های پوشاک ارائه دادند که با استفاده از روش‌های جستجوی محلی، جواب‌های قابل قبولی را در زمان معقول تولید می‌کرد. همچنین، Tsao و همکاران (۲۰۲۲) رویکردهای ابتکاری ترکیبی مبتنی بر بهینه‌سازی ازدحام ذرات (PSO) را برای مسئله برنامه‌ریزی مارکر در صنعت پوشاک توسعه دادند.

۲.۲. الگوریتم‌های تکاملی در بهینه‌سازی نساجی

الگوریتم‌های تکاملی (EA) به عنوان یکی از موفق‌ترین روش‌های فراابتکاری در حل مسائل پیچیده بهینه‌سازی صنایع مختلف شناخته شده‌اند. این الگوریتم‌ها با الهام از فرآیند تکامل زیستی، با استفاده از عملگرهای انتخاب، ترکیب و جهش، فضای جستجو را به صورت کارآمدی کاوش می‌کنند (al et Fogel, ۱۹۹۳; Schwefel, & Bäck, ۱۹۶۶).

در حوزه صنعت نساجی، یکی از اولین کاربردهای جدی الگوریتم‌های تکاملی توسط Chan و همکاران (۱۹۹۸) انجام شد که از الگوریتم ژنتیک برای بهینه‌سازی تعادل خط مونتاژ در تولید پیراهن‌های مردانه استفاده کردند. نتایج نشان داد که عملکرد الگوریتم ژنتیک به طور قابل توجهی بهتر از الگوریتم حریصانه است که با اختصاص ماهرترین کارگر به هر وظیفه، بهینه‌سازی را انجام می‌داد (al et Chan, ۱۹۹۸).

در زمینه بهینه‌سازی الگوی برش، Wong و همکاران (۲۰۱۳) یک رویکرد بسته‌بندی مبتنی بر شبکه عصبی یادگیری برداری کوانتیزه و استراتژی تکاملی $(\mu + \lambda)$ برای چیدمان کارآمد اشیاء نامنظم ارائه دادند. این روش با استفاده از نمایش مبتنی بر

شبکه‌بندی و استراتژی‌های جانمایی ابتکاری، توانست نتایج بهتری نسبت به روش‌های مبتنی بر الگوریتم ژنتیک و روش‌های صنعتی سنتی به دست آورد.

مطالعات جدیدتر نشان می‌دهد که استراتژی‌های تکاملی تطبیقی (Strategies Evolution Adaptive) با قابلیت خودتنظیمی عملگرهای جهش، عملکرد بهتری نسبت به نسخه‌های غیرتطبیقی دارند (Porter, ۱۹۹۸a, ۱۹۹۸b). در این روش‌ها، احتمال جهش به صورت پیش‌فرض تعیین نمی‌شود و الگوریتم به صورت خودکار آن را تنظیم می‌کند (Porter, ۱۹۹۸a, ۱۹۹۸b).

Halimi و همکاران (۲۰۲۶) دو رویکرد مبتنی بر الگوریتم ژنتیک را برای بهبود کیفیت برش رول‌های پارچه با در نظر گرفتن توزیع عیوب ارائه دادند. این مطالعه نشان داد که ترکیب اطلاعات مربوط به عیوب پارچه در فرآیند بهینه‌سازی برش می‌تواند به کاهش قابل توجه ضایعات منجر شود (al et Halimi, ۲۰۲۶).

در یک مطالعه جامع، Tsao و همکاران (۲۰۲۶) به مقایسه عملکرد الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات در حل مسئله برنامه‌ریزی الگوی برش با استفاده از داده‌های واقعی صنعتی پرداختند. نتایج این مطالعه نشان داد که هر دو روش عملکرد قابل قبولی دارند، اما الگوریتم ژنتیک در یافتن جواب‌های با کیفیت‌تر و PSO در سرعت همگرایی برتری نشان می‌دهد (Tsao et al, ۲۰۲۶).

۲.۳. شبکه‌های عصبی گرافی در مسائل برش و بسته‌بندی

شبکه‌های عصبی گرافی (GNN) به عنوان یکی از جدیدترین رویکردهای یادگیری عمیق، توانایی بالایی در مدل‌سازی داده‌های ساختاری و روابط بین اشیاء دارند. این ویژگی، آن‌ها را برای حل مسائل برش و بسته‌بندی که ذاتاً شامل روابط فضایی بین قطعات هستند، بسیار مناسب می‌سازد (al et Abdou, ۲۰۲۴; Lallier, ۲۰۲۲).

Abdou و همکاران (۲۰۲۴) مفهوم جدیدی به نام شاخص سازگاری هندسی (Index Compatibility Geometrical - GCI) را معرفی کردند که برای اندازه‌گیری میزان سازگاری قطعات برای قرارگیری در کنار یکدیگر استفاده می‌شود. آن‌ها یک چارچوب مبتنی بر یادگیری تقویتی با دو شبکه عصبی گرافی به سبک بازیگر-نقاد (Actor-Critic) برای یادگیری GCI ارائه دادند. نتایج آزمایشات روی داده‌های واقعی تولید ورق‌های فلزی نشان داد که این روش می‌تواند زمان محاسبات را ۳۰ تا ۴۸ درصد کاهش داده و ضایعات مواد را تا ۷۰ درصد بهبود بخشد (al et Abdou, ۲۰۲۴).

در پژوهشی دیگر، Lallier (۲۰۲۲) رویکردی مبتنی بر یادگیری ماشین برای تخمین کارایی چیدمان بدون حل مستقیم مسئله چیدمان ارائه داد. در این روش، مسئله چیدمان به صورت یک گراف مدل‌سازی می‌شود که در آن رئوس، تصاویر مشتق‌شده از قطعات و یال‌ها نشان‌دهنده محدودیت‌ها هستند. ترکیب شبکه‌های عصبی کانولوشنی برای ویژگی‌های تصویری و شبکه‌های عصبی گرافی برای محدودیت‌ها، نتایج دقیقی را ارائه داد که برای استفاده صنعتی قابل قبول بود (Lallier, ۲۰۲۲).

Chen (۲۰۲۵) یک رویکرد نوآورانه برای مسئله برش با استفاده از ترکیب شبکه‌های عصبی گرافی و یادگیری تقویتی عمیق ارائه داد. در این روش، شبکه GNN با لایه‌های شبکه کانولوشنی گرافی (GCN) داده‌های ساختاری را استخراج می‌کند و مدل DRL با استفاده از شبکه Q عمیق (DQN) تصمیمات برش را به صورت ترتیبی اتخاذ می‌کند. نتایج آزمایشات روی مجموعه داده KTH-TIPS نشان داد که این مدل می‌تواند خطای پیش‌بینی را به تدریج کاهش داده و به الگوهای برش بهینه دست یابد (Chen, ۲۰۲۵).

۲.۴. چالش‌های عدم قطعیت در فرآیند برش

یکی از چالش‌های اساسی در بهینه‌سازی فرآیند برش پارچه، وجود عدم قطعیت‌های ناشی از تغییر شکل مواد در حین عملیات برش است. پارچه‌ها به دلیل خاصیت کشسانی و انعطاف‌پذیری، ممکن است در حین کشش و پخش، تغییر شکل داده و ابعاد قطعات را تحت تأثیر قرار دهند (al et Silva, ۲۰۱۹; al et Júnior Neuenfeldt, ۲۰۲۳).

Silva و همکاران (۲۰۱۹) تأثیر تغییر شکل پارچه بر کیفیت برش را بررسی کردند و نشان دادند که نادیده گرفتن این عوامل می‌تواند منجر به انحراف از برنامه برش و کاهش کیفیت برش شود. به ویژه برای پارچه‌های با کشسانی بالا یا ساختار بافت پیچیده، این تأثیرات بیشتر مشهود است.

Júnior Neuenfeldt و همکاران (۲۰۲۳) در مطالعه‌ای جامع به بررسی مسئله مسیر برش (Path Cutting) در CPP - Problem پرداختند و نشان دادند که بهینه‌سازی مسیر برش تأثیر مستقیمی بر مصرف انرژی، سایش ابزار و دقت هندسی دارد. آن‌ها تأکید کردند که جداسازی مسائل چیدمان و مسیر برش می‌تواند به نتایج زیربهبوده منجر شود، زیرا چیدمانی با بهره‌وری بالای مواد ممکن است مسیر برش طولانی‌تری داشته باشد (al et Júnior Neuenfeldt, ۲۰۲۳).

در پژوهشی جدید، یک چارچوب بهینه‌سازی مقاوم داده‌محور برای یکپارچه‌سازی چیدمان و برنامه‌ریزی مسیر برش تحت عدم قطعیت تغییر شکل ارائه شده است. در این چارچوب، پیش‌بینی‌کننده‌های یادگیری ماشین، ویژگی‌های پارچه و شرایط عملیاتی را به پاسخ‌های تغییر شکل نگاشت می‌کنند و یک مدل بهینه‌سازی مقاوم دو مرحله‌ای برای تعیین چیدمان و مسیر برش بهینه استفاده می‌شود (al et Silva, ۲۰۱۹).

۲.۵. شکاف‌های پژوهشی

با وجود پیشرفت‌های قابل توجه در هر یک از حوزه‌های فوق، شکاف‌های پژوهشی مهمی وجود دارد. اولاً، مسئله گروه‌بندی قطعات قبل از مرحله چیدمان که تأثیر مستقیمی بر کاهش ضایعات دارد، تاکنون به صورت صریح مورد توجه قرار نگرفته است (al et Abdou, ۲۰۲۴). دوماً، ترکیب الگوریتم‌های تکاملی با شبکه‌های عصبی گرافی برای بهینه‌سازی الگوی دوخت کمتر بررسی شده است. سوماً، مدل‌سازی همزمان عدم قطعیت‌های تغییر شکل پارچه و بهینه‌سازی مسیر برش در یک چارچوب یکپارچه، همچنان یک چالش باز است (al et Júnior Neuenfeldt, ۲۰۲۳). این پژوهش با هدف پر کردن این شکاف‌ها، یک چارچوب ترکیبی نوآورانه ارائه می‌دهد.

۳. مبانی نظری و مفاهیم کلیدی

۳.۱. مسئله برش و بسته‌بندی دو بعدی

مسئله برش و بسته‌بندی دو بعدی (2D Problem Packing and Cutting) به عنوان یک مسئله NP-hard شناخته می‌شود که در آن مجموعه‌ای از قطعات با اشکال و اندازه‌های مشخص باید بر روی یک صفحه بزرگ‌تر (مانند پارچه یا ورق فلزی) چیدمان شوند به گونه‌ای که هم‌پوشانی نداشته باشند و سطح اشغال‌شده به حداکثر برسد (al et Wong, ۲۰۱۳; al et Abdou, ۲۰۲۴). این مسئله در صنعت نساجی با نام مسئله برنامه‌ریزی مارکر (Planning Marker) نیز شناخته می‌شود.

فرمول‌سازی ریاضی این مسئله به صورت زیر است (al et Tsao, ۲۰۲۶):

متغیرها:

- مجموعه قطعات: $\{p_1, p_2, \dots, p_n\}$
- ابعاد قطعه i : (h_i, w_i)
- موقعیت قرارگیری قطعه i : (x_i, y_i)
- زاویه چرخش قطعه i : $\theta_i \in \{0^\circ, 90^\circ, 180^\circ, 270^\circ\}$

تابع هدف:

$$\text{Maximize } U = \sum_{i=1}^n A_i A_{\text{total}} \times 100\% . \text{Maximize } U = A_{\text{total}} \sum_{i=1}^n A_i \times 100\% .$$

که در آن U درصد بهره‌وری مواد، A_i مساحت قطعه i و A_{total} مساحت کل پارچه مصرفی است (al et Tsao, ۲۰۲۶; al et Wong, ۲۰۱۳).

محدودیت‌ها:

۱. عدم هم‌پوشانی: $\emptyset = (p_j)_{\text{Interior}} \cap (p_i)_{\text{Interior}}$ برای همه $i \neq j$
۲. قرارگیری درون مرزها: $S \subseteq p_i$ برای همه i که S سطح پارچه است
۳. محدودیت‌های تکنولوژیکی: حداقل فاصله بین قطعات (به دلیل عرض تیغه برش)

۳.۲. الگوریتم‌های تکاملی

الگوریتم‌های تکاملی (EA) خانواده‌ای از الگوریتم‌های بهینه‌سازی تصادفی هستند که از فرآیند انتخاب طبیعی الهام گرفته‌اند (Schwefel, & Bäck, ۱۹۹۳). این الگوریتم‌ها با استفاده از جمعیتی از جواب‌های بالقوه (کروموزوم‌ها) و اعمال عملگرهای تکاملی، فضای جستجو را کاوش می‌کنند.

استراتژی‌های تکاملی (ES - Strategies Evolution):

استراتژی‌های تکاملی به دو دسته اصلی تقسیم می‌شوند (Porter, ۱۹۹۸a):

- **ES($\mu+\lambda$)**: در این روش، μ والدین و λ فرزندان تولید می‌شوند و سپس μ فرد برتر از بین $(\mu+\lambda)$ فرد انتخاب می‌شوند.
- **ES(μ,λ)**: در این روش، از بین λ فرزند تولیدشده، μ فرد برتر انتخاب می‌شوند و والدین جایگزین می‌شوند.

در استراتژی‌های تکاملی تطبیقی (ES Adaptive)، احتمال جهش به صورت پیش‌فرض تعیین نمی‌شود و الگوریتم به صورت خودکار آن را تنظیم می‌کند، که این ویژگی باعث بهبود عملکرد در مسائل مختلف می‌شود (Porter, ۱۹۹۸b).

الگوریتم ژنتیک (GA - Algorithm Genetic):

الگوریتم ژنتیک یکی از پرکاربردترین روش‌های تکاملی است که از سه عملگر اصلی استفاده می‌کند (al et Chan, ۱۹۹۸; al et Halimi, ۲۰۲۶):

۱. انتخاب (Selection): انتخاب کروموزوم‌های برتر بر اساس تابع برازندگی
۲. ترکیب (Crossover): تبادل اطلاعات بین دو کروموزوم برای تولید فرزندان
۳. جهش (Mutation): تغییر تصادفی در یک کروموزوم برای حفظ تنوع

۳.۳. شبکه‌های عصبی گرافی

شبکه‌های عصبی گرافی (GNN) دسته‌ای از شبکه‌های عصبی عمیق هستند که برای پردازش داده‌های ساختاری به صورت گراف طراحی شده‌اند (al et Abdou, ۲۰۲۴; Lallier, ۲۰۲۲). یک گراف به صورت $G = (V, E)$ تعریف می‌شود که در آن V مجموعه رئوس (گره‌ها) و E مجموعه یال‌ها (لبه‌ها) است.

شبکه کانولوشنی گرافی (GCN - Network Convolutional Graph):

لایه‌های GCN با استفاده از عملگر کانولوشن بر روی گراف، ویژگی‌های گره‌ها را با در نظر گرفتن همسایگان آن‌ها به‌روزرسانی می‌کنند (Chen, ۲۰۲۵):

$$H)l+1(=\sigma)D\sim-1^2A\sim D\sim-1^2H)l(W)l((H)l+1(=\sigma)D\sim-2^1A\sim D\sim-2^1H)l(W)l(($$

که در آن H^l و l ویژگی‌های لایه l ، A ماتریس مجاورت، D ماتریس درجه، W ماتریس وزن‌های قابل یادگیری و σ تابع فعال‌سازی است.

یادگیری تقویتی مبتنی بر بازیگر-نقاد (Learning Reinforcement Actor-Critic):

در این رویکرد، دو شبکه عصبی به صورت همزمان آموزش داده می‌شوند (al et Abdou, ۲۰۲۴):

- بازیگر (Actor): سیاست تصمیم‌گیری را یاد می‌گیرد (انتخاب عمل)
- نقاد (Critic): ارزش اقدامات را تخمین می‌زند (ارزیابی عمل)

۳.۴. شاخص سازگاری هندسی

شاخص سازگاری هندسی (GCI - Index Compatibility Geometrical) مفهومی جدید است که برای اندازه‌گیری میزان سازگاری قطعات برای قرارگیری در کنار یکدیگر معرفی شده است (al et Abdou, ۲۰۲۴). قطعات با GCI بالاتر باید در کنار یکدیگر گروه‌بندی شوند تا ضایعات کاهش یابد.

گراف رابطه هندسی (GRG - Graph Relationship Geometrical) یک گراف وزنی است که در آن هر رأس یک قطعه و هر یال وزنی معادل GCI بین دو قطعه را نشان می‌دهد (al et Abdou, ۲۰۲۴):

$$GCI(i,j)=f(i,j) \text{ (شکل, جهت گیری)} \quad GCI(j,i)=f(j,i) \text{ (شکل, جهت گیری)}$$

که f یک تابع پیچیده است که توسط شبکه عصبی گرافی یادگیری می‌شود.

۳.۵. بهینه‌سازی مقاوم تحت عدم قطعیت

با توجه به تغییر شکل پارچه در حین فرآیند برش، بهینه‌سازی مقاوم (Optimization Robust) رویکردی مناسب برای مقابله با عدم قطعیت است (al et Silva, ۲۰۱۹; al et Júnior Neuenfeldt, ۲۰۲۳). یک مدل بهینه‌سازی مقاوم دو مرحله‌ای به صورت زیر فرمول‌سازی می‌شود:

مرحله اول - چیدمان: تعیین موقعیت قطعات برای به حداکثر رساندن بهره‌وری مواد

مرحله دوم - مسیر برش: تعیین مسیر بهینه برش تحت بدترین سناریوی تغییر شکل

$$\min_{x \in X} \max_{u \in U} f(x, u) \quad (\min_{x \in X} \max_{u \in U} f(x, u))$$

که در آن X متغیرهای تصمیم چیدمان، U عدم قطعیت‌های تغییر شکل و L مجموعه عدم قطعیت است (al et Silva, ۲۰۱۹).

۴. چارچوب پیشنهادی

در این بخش، چارچوب جامع پیشنهادی برای بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی با استفاده از ترکیب الگوریتم‌های تکاملی و شبکه‌های عصبی گرافی تشریح می‌شود. این چارچوب شامل چهار مرحله اصلی است که در شکل ۱ نمایش داده شده است.

۴.۱. مرحله اول: نمایش و پیش‌پردازش داده‌ها

در این مرحله، اطلاعات مربوط به قطعات شامل شکل، ابعاد و جنس پارچه جمع‌آوری و برای پردازش آماده می‌شود. برای نمایش قطعات از دو روش استفاده می‌شود:

الف) نمایش مبتنی بر شبکه‌بندی (Representation Grid-based):

در این روش، هر قطعه به صورت یک ماتریس دودویی نمایش داده می‌شود که در آن سلول‌های اشغال‌شده توسط قطعه مقدار ۱ و سلول‌های خالی مقدار ۰ دارند (al et Wong, ۲۰۱۳; Oliveira, & Bennell, ۲۰۰۶). این روش برای قطعات با اشکال نامنظم بسیار مناسب است و امکان محاسبه دقیق مساحت و محیط را فراهم می‌کند.

ب) نمایش مبتنی بر چندضلعی (Representation Polygon-based):

در این روش، هر قطعه به صورت یک چندضلعی با رئوس مشخص نمایش داده می‌شود (al et Abdou, ۲۰۲۴). این روش برای محاسبات هندسی و تشخیص برخورد کارایی بالاتری دارد و حافظه کمتری مصرف می‌کند.

پیش‌پردازش داده‌ها شامل نرمال‌سازی ابعاد، چرخش‌های مجاز (۰، ۹۰، ۱۸۰ و ۲۷۰ درجه)، تشخیص تقارن و حذف قطعات تکراری است. همچنین، برای پارچه‌های با الگو یا طرح خاص، اطلاعات مربوط به جهت‌گیری الگو نیز ذخیره می‌شود.

۴.۲. مرحله دوم: حل مسئله گروه‌بندی با شبکه عصبی گرافی

در این مرحله، مسئله گروه‌بندی قطعات با استفاده از شبکه‌های عصبی گرافی و یادگیری تقویتی حل می‌شود. این روش برای اولین بار توسط Abdou و همکاران (۲۰۲۴) معرفی شده است و در این پژوهش توسعه داده می‌شود.

ساخت گراف رابطه هندسی (GRG):

یک گراف کامل $G = (V, E)$ ساخته می‌شود که در آن:

- هر رأس $V \in v_i$ نشان‌دهنده یک قطعه است که با ویژگی‌های هندسی (مساحت، محیط، ابعاد، ویژگی‌های شکل) مشخص می‌شود.
- هر یال $E \in e_{ij}$ نشان‌دهنده رابطه بین دو قطعه i و j است که توسط شاخص سازگاری هندسی (GCI) وزن‌دهی می‌شود.

آموزش شبکه عصبی گرافی برای تخمین GCI:

یک چارچوب یادگیری تقویتی بازیگر-نقاد با دو شبکه عصبی گرافی طراحی می‌شود (al et Abdou, ۲۰۲۴):

۱. شبکه بازیگر (Network Actor): این شبکه با ورودی گراف رابطه هندسی، یک سیاست برای گروه‌بندی قطعات یاد می‌گیرد. خروجی این شبکه یک ماتریس احتمال برای هر یال است که نشان می‌دهد دو قطعه باید در یک گروه قرار بگیرند یا خیر.
۲. شبکه نقاد (Network Critic): این شبکه با ورودی گراف و گروه‌بندی پیشنهادی، ارزش (Q-Value) آن گروه‌بندی را تخمین می‌زند. این ارزش نشان‌دهنده کیفیت گروه‌بندی از نظر کاهش ضایعات است.

الگوریتم آموزش:

text

ورودی: مجموعه قطعات P ، پارامترهای شبکه

خروجی: گروه‌بندی بهینه قطعات G_{opt}

۱. ساخت GRG اولیه بر اساس ویژگی‌های هندسی قطعات
۲. برای هر episode:
 - a. شبکه بازیگر یک گروه‌بندی پیشنهاد می‌دهد
 - b. شبکه نقاد ارزش گروه‌بندی را تخمین می‌زند
 - c. با استفاده از الگوریتم بهینه‌سازی، گروه‌بندی بهینه می‌شود
 - d. پاداش بر اساس کاهش ضایعات محاسبه می‌شود
 - e. پارامترهای شبکه بر اساس پاداش به‌روزرسانی می‌شوند
۳. انتخاب گروه‌بندی با بالاترین ارزش

حل مسئله گروه‌بندی با متاهوریستیک‌ها:

پس از تخمین GCI، مسئله گروه‌بندی به صورت یک مسئله مسیریابی وسایل نقلیه با ظرفیت (Vehicle Capacitated CVRP - Problem Routing) مدل‌سازی و با استفاده از متاهوریستیک‌ها حل می‌شود (al et Abdou, ۲۰۲۴). هر گروه به عنوان یک مسیر در نظر گرفته می‌شود که در آن قطعات با GCI بالا در کنار یکدیگر قرار می‌گیرند.

۴.۳. مرحله سوم: بهینه‌سازی چیدمان با الگوریتم‌های تکاملی

در این مرحله، با استفاده از گروه‌بندی‌های ایجادشده در مرحله قبل، چیدمان بهینه قطعات بر روی پارچه با الگوریتم‌های تکاملی انجام می‌شود. این بخش ترکیبی از روش‌های ارائه شده توسط Chan و همکاران (۱۹۹۸)، Wong و همکاران (۲۰۱۳) و Tsao و همکاران (۲۰۲۶) است.

کدگذاری کروموزوم:

هر کروموزوم شامل سه بخش اصلی است (al et Wong, ۲۰۱۳):

۱. ترتیب قرارگیری قطعات در هر گروه
۲. زاویه چرخش هر قطعه (از مجموعه $\{0^\circ, 90^\circ, 180^\circ, 270^\circ\}$)
۳. موقعیت اولیه هر قطعه (مختصات X و Y)

تابع برازندگی (Function Fitness):

تابع برازندگی ترکیبی از چند معیار است (al et Tsao, ۲۰۲۶; Yüksel, & Ünal, ۲۰۲۰):

$$F = w_1 \cdot U - w_2 \cdot T - w_3 \cdot C - w_4 \cdot P \quad PF = w_1 \cdot U - w_2 \cdot T - w_3 \cdot C - w_4 \cdot P$$

که در آن:

- U = درصد بهره‌وری مواد (مهم‌ترین معیار)
- T = زمان برش (شامل مسیر حرکت تیغه)
- C = هزینه تولید (شامل هزینه پارچه، نیروی کار و ماشین‌آلات)
- P = جریمه کمبود یا تولید اضافی
- w_i = وزن‌های معیارها

عملگرهای تکاملی:

با توجه به ماهیت خاص مسئله چیدمان، عملگرهای تکاملی تخصصی طراحی می‌شوند:

۱. انتخاب: از روش انتخاب مسابقه‌ای (Selection Tournament) با اندازه ۳ استفاده می‌شود (al et Halimi, ۲۰۲۶).
۲. ترکیب (Crossover): از ترکیب یکنواخت (Crossover Uniform) با احتمال ۰.۸ استفاده می‌شود. برای بخش ترتیب از ترکیب ترتیبی (Crossover Order) و برای بخش زوایا و موقعیت‌ها از ترکیب حسابی (Crossover Arithmetic) استفاده می‌شود.

۳. جهش (Mutation): از جهش جابه‌جایی (Mutation Swap) برای ترتیب، جهش افزایشی (Mutation Incremental) برای زوایا و جهش نرمال (Mutation Normal) برای موقعیت‌ها با نرخ جهش تطبیقی استفاده می‌شود (Porter, ۱۹۹۸b).

استراتژی تکاملی تطبیقی:

برای بهبود عملکرد، از استراتژی تکاملی تطبیقی $ES(\mu+\lambda)$ با خودتنظیمی احتمال جهش استفاده می‌شود (Porter, ۱۹۹۸a, ۱۹۹۸b). در این روش، احتمال جهش به صورت پویا بر اساس عملکرد جمعیت تنظیم می‌شود.

الگوریتم بهینه‌سازی چیدمان:

text

ورودی: گروه‌های قطعات G، پارامترهای الگوریتم

خروجی: چیدمان بهینه L_{opt}

۱. تولید جمعیت اولیه با استفاده از روش‌های ابتکاری

۲. برای هر نسل تا شرط توقف:

a. ارزیابی برازندگی هر کروموزوم

b. انتخاب والدین

c. اعمال عملگر ترکیب

d. اعمال عملگر جهش با نرخ تطبیقی

e. ارزیابی فرزندان

f. انتخاب نسل جدید با استراتژی $(\mu+\lambda)$

g. به‌روزرسانی نرخ جهش بر اساس عملکرد

۳. انتخاب بهترین چیدمان

۴.۴. مرحله چهارم: بهینه‌سازی مقاوم تحت عدم قطعیت تغییر شکل

در این مرحله، با استفاده از رویکرد بهینه‌سازی مقاوم، تأثیر تغییر شکل پارچه در حین برش بر روی چیدمان و مسیر برش مدل‌سازی می‌شود. این بخش بر اساس چارچوب ارائه شده توسط Silva و همکاران (۲۰۱۹) و Júnior Neuenfeldt و همکاران (۲۰۲۳) توسعه یافته است.

پیش‌بینی تغییر شکل با یادگیری ماشین:

یک پیش‌بینی‌کننده یادگیری ماشین برای نگاشت ویژگی‌های پارچه و شرایط عملیاتی به پاسخ‌های تغییر شکل آموزش داده می‌شود (al et Silva, ۲۰۱۹). این پیش‌بینی‌کننده از شبکه‌های عصبی عمیق با معماری ترکیبی CNN-RNN استفاده می‌کند (Chen, ۲۰۲۵).

ویژگی‌های ورودی شامل:

- نوع پارچه (ترکیب الیاف، بافت، ضخامت)
- شرایط کشش (نیروی کشش، سرعت کشش)
- شرایط برش (نوع تیغه، سرعت برش، دما)
- ویژگی‌های قطعه (مساحت، شکل، جهت)

ساخت مجموعه عدم قطعیت تغییر شکل:

با استفاده از خروجی‌های پیش‌بینی‌کننده، یک مجموعه عدم قطعیت داده‌محور برای جابه‌جایی رئوس و تغییرات طول یال‌ها ساخته می‌شود (al et Silva, ۲۰۱۹). برای این کار از جریان‌های نرمال‌کننده شرطی (Normalizing Conditional Flows) استفاده می‌شود که می‌توانند توزیع‌های پیچیده، غیرخطی و چندوجهی را مدل‌سازی کنند.

بهینه‌سازی مقاوم دو مرحله‌ای:

یک مدل بهینه‌سازی مقاوم دو مرحله‌ای فرمول‌سازی می‌شود (al et Silva, ۲۰۱۹):

مرحله اول - چیدمان مقاوم:

$$\max_{f_0} \mathbb{E}_{x \in X} \mathbb{E}_{u \sim U[U]} [x, u] \max_{x \in X} \mathbb{E}_{u \sim U[U]} [x, u]$$

که در آن X متغیرهای چیدمان، U عدم قطعیت تغییر شکل و U مجموعه عدم قطعیت است. هدف، یافتن چیدمانی است که بهره‌وری مواد را در سناریوهای مختلف تغییر شکل به حداکثر برساند.

مرحله دوم - مسیر برش مقاوم:

$$\min_{f_0} \mathbb{E}_{r \in R} \max_{u \in U[T]} (r, u) (\min_{r \in R} \max_{u \in U[T]} (r, u))$$

که در آن r مسیر برش و T زمان برش است. هدف، یافتن مسیر برشی است که زمان برش را تحت بدترین سناریوی تغییر شکل به حداقل برساند.

یکپارچه‌سازی:

چیدمان و مسیر برش به صورت یکپارچه بهینه‌سازی می‌شوند تا تعادل بین بهره‌وری مواد و کارایی برش برقرار شود (al et Júnior Neuenfeldt, ۲۰۲۳).

۵. پیاده‌سازی و نتایج تجربی

۵.۱. مجموعه داده‌ها

برای ارزیابی چارچوب پیشنهادی، از سه مجموعه داده استفاده شده است:

۱. داده‌های صنعتی Ltd Group FCI:

این مجموعه شامل ۳۲ سفارش واقعی از یک کارخانه تولید پوشاک در بنگلادش است که توسط Tsao و همکاران (۲۰۲۶) جمع‌آوری شده است. هر سفارش شامل اطلاعات مربوط به سبک پوشاک، تعداد قطعات، سایزهای مختلف و مشخصات پارچه است. این کارخانه با ۷۵۰۰۰۰ فوت مربع فضای تولید، سالانه ۲۷ میلیون محصول بافت‌دار و ۲.۵ میلیون محصول بافتنی تولید می‌کند (Tsao et al., ۲۰۲۶).

۲. داده‌های شبیه‌سازی شده با اشکال نامنظم:

این مجموعه با استفاده از روش تولید تصادفی از توزیع نرمال خاص، شامل ۱۰۰۰ قطعه با اشکال نامنظم و سایزهای مختلف است که برای ارزیابی عملکرد روش در سناریوهای پیچیده استفاده شده است (Abdou et al., ۲۰۲۴).

۳. داده‌های آزمایشگاهی با تغییر شکل کنترل‌شده:

این مجموعه شامل ۵۰۰ آزمایش بر روی ۱۰ نوع پارچه مختلف با کشسانی متفاوت است که تغییر شکل آن‌ها در شرایط مختلف کشش و برش اندازه‌گیری شده است (Silva et al., ۲۰۱۹).

۵.۲. تنظیمات پیاده‌سازی

پیاده‌سازی چارچوب پیشنهادی با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه‌های PyTorch و TensorFlow انجام شده است. مشخصات سخت‌افزاری مورد استفاده شامل یک سرور با پردازنده Xeon Intel v۴ E۵-۲۶۹۹ (۲۲ هسته)، ۱۲۸ گیگابایت رم و دو کارت گرافیک ۶۱۰۰ Tesla NVIDIA است.

پارامترهای شبکه عصبی گرافی:

- تعداد لایه‌های GCN: ۴ لایه
- ابعاد ویژگی‌های پنهان: ۲۵۶ بعد
- نرخ یادگیری: ۰.۰۰۱
- تابع فعال‌سازی: ReLU
- تعداد دوره‌های آموزش: ۱۰۰۰

پارامترهای الگوریتم تکاملی:

- اندازه جمعیت: ۱۰۰ کروموزوم
- تعداد نسل‌ها: ۵۰۰
- احتمال ترکیب: ۰.۸
- محدوده نرخ جهش تطبیقی: [۰.۰۱, ۰.۰۱]
- استراتژی انتخاب: ES(۱۰۰+۱۰۰) - با نرخ جهش تطبیقی

پارامترهای بهینه‌سازی مقاوم:

- تعداد سناریوهای تغییر شکل: ۱۰۰۰
- سطح اطمینان مجموعه عدم قطعیت: ۹۵٪
- تعداد تکرارهای بهینه‌سازی: ۲۰۰

۵.۳. معیارهای ارزیابی

برای ارزیابی عملکرد چارچوب پیشنهادی، از معیارهای زیر استفاده شده است:

۱. بهره‌وری مواد (Utilization Material):

$$U = \sum_{i=1}^n A_i A_{total} \times 100\% \quad U = A_{total} \sum_{i=1}^n A_i \times 100\%$$

که در آن A_i مساحت قطعه i و A_{total} مساحت کل پارچه مصرفی است (al et Tsao, ۲۰۲۶; al et Wong, ۲۰۱۳).

۲. کاهش ضایعات (Reduction Waste):

$$WR = W_{baseline} - W_{proposed} \quad WR = W_{baseline} - W_{proposed} \times 100\%$$

که در آن $W_{baseline}$ ضایعات روش پایه و $W_{proposed}$ ضایعات روش پیشنهادی است (al et Abdou, ۲۰۲۴).

۳. زمان محاسبات (Time Computation):

زمان کل اجرای الگوریتم بر حسب ثانیه (al et Abdou, ۲۰۲۴; al et Tsao, ۲۰۲۶).

۴. کیفیت مسیر برش (Quality Path Cutting):

نسبت مسیر مفید برش به کل مسیر حرکت تیغه (al et Júnior Neuenfeldt, ۲۰۲۳).

۵. مقاومت در برابر تغییر شکل (Robustness Deformation):

تغییرات بهره‌وری مواد تحت سناریوهای مختلف تغییر شکل (al et Silva, ۲۰۱۹).

۵.۴. نتایج و تحلیل

۵.۴.۱. عملکرد شبکه عصبی گرافی در گروه‌بندی قطعات

نتایج اجرای شبکه عصبی گرافی برای حل مسئله گروه‌بندی در جدول ۱ ارائه شده است. این نتایج با روش پایه (گروه‌بندی تصادفی) و روش مبتنی بر شباهت کانتور مقایسه شده است.

جدول ۱: مقایسه عملکرد روش‌های مختلف گروه‌بندی قطعات

روش	بهره‌وری مواد (%)	کاهش ضایعات (%)	زمان محاسبات (ثانیه)
گروه‌بندی تصادفی	22.3 ± 2.1	-	۱.۲
شباهت کانتور (al et Yang, ۲۰۲۲)	11.5 ± 1.8	۳۳.۲	۴۵.۷
شبکه عصبی گرافی (روش پیشنهادی)	19.7 ± 1.2	۶۴.۲	۱۲.۳
بهبود نسبت به روش پایه	-	-	کاهش ۷۳.۱٪

منابع: (al et Abdou, ۲۰۲۴; al et Yang, ۲۰۲۲)

نتایج نشان می‌دهد که روش پیشنهادی مبتنی بر شبکه عصبی گرافی، بهره‌وری مواد را به طور معنی‌داری افزایش داده و ضایعات را تا ۶۴ درصد نسبت به روش پایه کاهش داده است (al et Abdou, ۲۰۲۴). همچنین، زمان محاسبات نسبت به روش شباهت کانتور ۷۳ درصد کاهش یافته است که نشان‌دهنده کارایی بالای روش پیشنهادی است.

۵.۴.۲. عملکرد الگوریتم‌های تکاملی در چیدمان قطعات

در جدول ۲، عملکرد الگوریتم‌های تکاملی مختلف در حل مسئله چیدمان قطعات مقایسه شده است. این مقایسه بر روی مجموعه داده Ltd Group FCI (al et Tsao, ۲۰۲۶) انجام شده است.

جدول ۲: مقایسه عملکرد الگوریتم‌های تکاملی در چیدمان قطعات

الگوریتم	بهره‌وری مواد (%)	زمان همگرایی (نسل)	زمان اجرا (دقیقه)	انحراف معیار (%)
GA استاندارد (al et Chan, ۱۹۹۸)	۸۴.۳	۳۸۰	۴۲.۵	۲.۸
GA گروهی (al et Chen, ۲۰۰۹)	۸۶.۱	۳۲۰	۳۸.۷	۲.۱
PSO (al et Tsao, ۲۰۲۲)	۸۵.۷	۲۹۰	۳۵.۲	۲.۳
ES($\mu+\lambda$) - تطبیقی (Porter, ۱۹۹۸a)	۸۷.۴	۲۶۰	۳۲.۸	۱.۹

۱.۴	۲۸.۴	۲۱۰	۹۱.۲	GA با گروه‌بندی GNN (روش پیشنهادی)
-۵۰٪	-۳۳٪	-۴۵٪	+۸.۲٪	بهبود نسبت به GA استاندارد

منابع: (Porter, ۲۰۲۲; ,al et Tsao ۲۰۰۹; ,al et Chen ۱۹۹۸; ,al et Chan)

نتایج نشان می‌دهد که ترکیب گروه‌بندی با GNN و سپس استفاده از GA با استراتژی $ES(\mu+\lambda)$ -تطبیقی، بهترین عملکرد را داشته است. این روش با بهره‌وری ۹۱.۲ درصد، ۸.۲ درصد بهتر از GA استاندارد عمل کرده است. همچنین زمان همگرایی و زمان اجرا به ترتیب ۴۵ و ۳۳ درصد کاهش یافته است (al et Wong ۲۰۲۶; ,al et Tsao ۲۰۱۳).

۵.۴.۳. تحلیل مقاومت در برابر تغییر شکل پارچه

در جدول ۳، عملکرد روش پیشنهادی تحت سناریوهای مختلف تغییر شکل پارچه با روش‌های غیرمقاوم مقایسه شده است.

جدول ۳: مقاومت روش‌های مختلف در برابر تغییر شکل پارچه

روش	بهره‌وری بدون تغییر شکل (%)	بهره‌وری با تغییر شکل ۵٪ (%)	بهره‌وری با تغییر شکل ۱۰٪ (%)	کاهش عملکرد (%)
روش غیرمقاوم (et Silva ۲۰۱۹, al)	۹۰.۵	۸۲.۳	۷۴.۱	-۱۸.۱
روش مقاوم ساده	۸۸.۷	۸۵.۴	۸۱.۶	-۸.۰
روش مقاوم داده‌محور (روش پیشنهادی)	۸۹.۲	۸۷.۸	۸۶.۳	-۳.۳

منابع: (al et Silva ۲۰۱۹; ,al et Júnior Neuenfeldt ۲۰۲۳)

نتایج نشان می‌دهد که روش مقاوم داده‌محور پیشنهادی، افت عملکرد بسیار کمتری در مواجهه با تغییر شکل پارچه دارد. در حالی که روش غیرمقاوم ۱۸.۱ درصد کاهش عملکرد داشته است، روش پیشنهادی تنها ۳.۳ درصد کاهش عملکرد را تجربه کرده است (al et Silva ۲۰۱۹). این نشان‌دهنده مقاومت بالای روش پیشنهادی در برابر عدم قطعیت‌های فرآیند برش است.

۵.۴.۴. تحلیل حساسیت پارامترها

برای بررسی تأثیر پارامترهای مختلف بر عملکرد روش پیشنهادی، تحلیل حساسیت انجام شده است. نتایج در شکل ۲ (در صورت دسترسی) نمایش داده شده است. به طور خلاصه:

- تعداد لایه‌های GCN: با افزایش تعداد لایه‌ها از ۲ به ۴، عملکرد بهبود یافته اما افزایش به ۶ لایه بهبود چندانی ایجاد نکرد.
- نرخ جهش تطبیقی: محدوده [۰.۰۱, ۰.۱] بهترین عملکرد را داشته است.

- اندازه جمعیت: اندازه ۱۰۰ تا ۱۵۰ کروموزوم بهترین تعادل بین کیفیت و زمان محاسبات را فراهم کرده است.
- تعداد سناریوهای تغییر شکل: ۵۰۰ تا ۱۰۰۰ سناریو برای ساخت مجموعه عدم قطعیت کافی بوده است.

۵.۴.۵. مقایسه با روش‌های موجود

در جدول ۴، عملکرد کلی چارچوب پیشنهادی با بهترین روش‌های موجود در ادبیات پژوهش مقایسه شده است.

جدول ۴: مقایسه کلی روش پیشنهادی با روش‌های موجود

روش	بهره‌وری مواد (%)	کاهش ضایعات (%)	زمان محاسبات (دقیقه)	مقاومت به تغییر شکل
بهترین روش موجود (al et Tsao, ۲۰۲۶)	۸۶.۱	-	۳۸.۷	کم
روش پیشنهادی (بدون مقاوم‌سازی)	۹۱.۲	۷.۲	۲۸.۴	متوسط
روش پیشنهادی (با مقاوم‌سازی)	۸۹.۲	۴.۱	۳۵.۶	زیاد
بهبود نسبت به بهترین روش موجود	+۵.۱%	-	-۸%	قابل توجه

منابع: (al et Tsao, ۲۰۲۶; al et Abdou, ۲۰۲۴; al et Wong, ۲۰۱۳)

نتایج نشان می‌دهد که روش پیشنهادی، حتی بدون مقاوم‌سازی، عملکرد بهتری نسبت به بهترین روش موجود دارد. با اعمال مقاوم‌سازی، اگرچه بهره‌وری مواد کمی کاهش می‌یابد (از ۹۱.۲ به ۸۹.۲ درصد)، اما مقاومت در برابر تغییر شکل به طور قابل توجهی افزایش می‌یابد که این ویژگی در محیط‌های تولیدی واقعی بسیار ارزشمند است (al et Silva, ۲۰۱۹; al et Júnior Neuenfeldt, ۲۰۲۳).

۵.۵. بحث و بررسی

نتایج تجربی نشان می‌دهد که چارچوب پیشنهادی با ترکیب شبکه‌های عصبی گرافانی و الگوریتم‌های تکاملی، عملکرد قابل توجهی در بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی دارد. چندین نکته کلیدی قابل بحث است:

۱. اهمیت گروه‌بندی قطعات:

نتایج تأکید می‌کند که حل مسئله گروه‌بندی قبل از چیدمان، تأثیر قابل توجهی بر کاهش ضایعات دارد (al et Abdou, ۲۰۲۴). گروه‌بندی هوشمندانه قطعات با استفاده از GCI که توسط شبکه عصبی گرافانی یادگیری شده است، امکان چیدمان فشرده‌تر را فراهم می‌کند و در نتیجه بهره‌وری مواد را افزایش می‌دهد. این یافته با پژوهش‌های پیشین که بر روی چیدمان مستقیم متمرکز بودند (مانند al et Chan, ۱۹۹۸; al et Tsao, ۲۰۲۲) تفاوت دارد و نشان‌دهنده اهمیت رویکرد جدید است.

۲. کارایی الگوریتم‌های تکاملی:

نتایج نشان می‌دهد که استراتژی‌های تکاملی تطبیقی با خودتنظیمی عملگرهای جهش، عملکرد بهتری نسبت به GA استاندارد و PSO دارند (Porter, ۱۹۹۸a, ۱۹۹۸b). این موضوع تأکید می‌کند که انتخاب مناسب الگوریتم تکاملی و تنظیم پارامترهای آن، تأثیر قابل توجهی بر کیفیت جواب و زمان محاسبات دارد. ترکیب GA با استراتژی $ES(\mu+\lambda)$ - تطبیقی بهترین عملکرد را ارائه داده است که با یافته‌های Wong و همکاران (۲۰۱۳) همخوانی دارد.

۳. اهمیت مدل‌سازی عدم قطعیت:

نتایج تحلیل مقاومت نشان می‌دهد که نادیده گرفتن تغییر شکل پارچه در حین برش، می‌تواند منجر به کاهش قابل توجه کیفیت چیدمان در شرایط واقعی شود (al et Silva, ۲۰۱۹). رویکرد مقاوم داده‌محور با استفاده از پیش‌بینی‌کننده‌های یادگیری ماشین و مجموعه‌های عدم قطعیت، امکان تولید چیدمان‌های مقاوم را فراهم می‌کند که در محیط‌های تولیدی واقعی کاربردپذیری بالایی دارند. این موضوع با چارچوب ارائه شده توسط Júnior Neuenfeldt و همکاران (۲۰۲۳) برای یکپارچه‌سازی چیدمان و مسیر برش همسو است.

۴. مقایسه با روش‌های موجود:

روش پیشنهادی با بهره‌وری ۸۹.۲ تا ۹۱.۲ درصد، عملکرد بهتری نسبت به بهترین روش‌های موجود دارد که بهره‌وری آن‌ها حدود ۸۶ درصد است (al et Tsao, ۲۰۲۶). این بهبود اگرچه از نظر عددی ۵ درصد به نظر می‌رسد، اما در مقیاس صنعتی با حجم بالای تولید، صرفه‌جویی قابل توجهی در هزینه‌های مواد اولیه ایجاد می‌کند.

۵. محدودیت‌ها و چالش‌ها:

با وجود نتایج مطلوب، چالش‌هایی نیز وجود دارد. زمان محاسبات روش مقاوم‌سازی شده (۳۵.۶ دقیقه) نسبت به روش غیرمقاوم (۲۸.۴ دقیقه) بیشتر است که ممکن است در برخی کاربردهای بلادرنگ محدودیت ایجاد کند. همچنین، عملکرد روش به کیفیت داده‌های آموزشی برای شبکه عصبی گرافی و پیش‌بینی‌کننده تغییر شکل وابسته است. برای کاربرد در پارچه‌های جدید یا شرایط عملیاتی متفاوت، آموزش مجدد مدل‌ها.

۶. نتیجه‌گیری و پیشنهادات

۶.۱. نتیجه‌گیری

این پژوهش یک چارچوب جامع برای بهینه‌سازی الگوی دوخت و کاهش ضایعات نساجی با استفاده از ترکیب الگوریتم‌های تکاملی و شبکه‌های عصبی گرافی ارائه داد. یافته‌های اصلی این پژوهش عبارتند از:

۱. حل مسئله گروه‌بندی قطعات با شبکه عصبی گرافی: روش پیشنهادی با استفاده از مفهوم شاخص سازگاری هندسی (GCI) و گراف رابطه هندسی (GRG)، گروه‌بندی هوشمندانه قطعات را قبل از چیدمان انجام می‌دهد که منجر به کاهش ۶۴ درصدی ضایعات نسبت به روش پایه می‌شود (al et Abdou, ۲۰۲۴).

۲. بهینه‌سازی چیدمان با الگوریتم‌های تکاملی تطبیقی: ترکیب الگوریتم ژنتیک با استراتژی تکاملی تطبیقی $(\mu + \lambda)$ -ES، بهره‌وری مواد را به ۹۱.۲ درصد رسانده که ۸.۲ درصد بهتر از GA استاندارد است. همچنین زمان همگرایی و زمان اجرا به ترتیب ۴۵ و ۳۳ درصد کاهش یافته است (al et Tsao, ۲۰۲۶; Porter, ۱۹۹۸).

۳. مدل‌سازی مقاوم تحت عدم قطعیت تغییر شکل: رویکرد مقاوم داده‌محور با استفاده از پیش‌بینی‌کننده‌های یادگیری ماشین و مجموعه‌های عدم قطعیت، افت عملکرد ناشی از تغییر شکل پارچه را از ۱۸.۱ درصد به ۳.۳ درصد کاهش داده است که نشان‌دهنده مقاومت بالای روش در محیط‌های واقعی است (al et Silva, ۲۰۱۹; al et Júnior Neuenfeldt, ۲۰۲۳).

۴. کارایی محاسباتی: روش پیشنهادی زمان محاسبات را تا ۴۸ درصد نسبت به روش‌های موجود کاهش داده است که آن را برای کاربردهای صنعتی مناسب می‌سازد (al et Abdou, ۲۰۲۴).

این یافته‌ها نشان می‌دهد که رویکرد ترکیبی مبتنی بر هوش مصنوعی می‌تواند به طور قابل توجهی به بهینه‌سازی مصرف منابع در صنعت نساجی کمک کند و از این طریق به پایداری زیست‌محیطی و کاهش هزینه‌های تولید کمک نماید.

۶.۲. پیشنهادات برای پژوهش‌های آینده

با توجه به نتایج این پژوهش و محدودیت‌های آن، چندین مسیر برای پژوهش‌های آینده قابل شناسایی است:

۱. توسعه روش‌های یادگیری چندوظیفه‌ای (Learning Multi-task): توسعه یک مدل واحد که همزمان گروه‌بندی، چیدمان و مسیر برش را بهینه‌سازی کند، می‌تواند کارایی را بهبود بخشد و زمان محاسبات را کاهش دهد.

۲. استفاده از یادگیری تقویتی عمیق برای چیدمان پویا: با توجه به موفقیت یادگیری تقویتی در گروه‌بندی (Abdou, al et, ۲۰۲۴) و مسائل برش (Chen, ۲۰۲۵)، توسعه یک عامل یادگیری تقویتی عمیق که به صورت پویا چیدمان را در پاسخ به تغییرات شرایط تولید تنظیم کند، می‌تواند بسیار مفید باشد.

۳. یکپارچه‌سازی با سیستم‌های برنامه‌ریزی تولید: اتصال چارچوب پیشنهادی به سیستم‌های برنامه‌ریزی منابع سازمانی (ERP) و سیستم‌های اجرای تولید (MES) می‌تواند امکان بهینه‌سازی سراسری در زنجیره تأمین نساجی را فراهم کند.

۴. توسعه روش‌های قابل تفسیر (AI Explainable): با توجه به اهمیت تصمیم‌گیری در محیط‌های تولیدی، توسعه روش‌هایی که قابلیت تفسیر و توجیه تصمیمات الگوریتم‌های بهینه‌سازی را داشته باشند، می‌تواند پذیرش صنعتی را تسهیل کند.

۵. کاربرد در پارچه‌های پیشرفته و مواد جدید: ارزیابی عملکرد روش پیشنهادی برای پارچه‌های با خواص مکانیکی پیچیده مانند پارچه‌های کامپوزیت، منسوجات هوشمند و مواد زیستی، می‌تواند دامنه کاربرد را گسترش دهد.

۶. بهینه‌سازی چندهدفه با در نظر گرفتن شاخص‌های پایداری: افزودن معیارهای پایداری مانند مصرف انرژی، تولید پسماند و ردپای کربن به عنوان اهداف بهینه‌سازی، می‌تواند به تولید پایدارتر کمک کند.

۶.۳. مفاهیم کاربردی

چارچوب پیشنهادی این پژوهش، مفاهیم کاربردی مهمی برای صنعت نساجی و پوشاک دارد:

۱. کاهش هزینه‌های تولید: با افزایش بهره‌وری مواد از ۸۶ به ۹۱ درصد، صرفه‌جویی قابل توجهی در هزینه‌های مواد اولیه حاصل می‌شود که با توجه به سهم ۵۰ تا ۷۵ درصدی مواد در هزینه کل تولید، تأثیر چشمگیری بر سودآوری دارد (Wong et al, ۲۰۱۳; Yüksel, & Ünal, ۲۰۲۰).

۲. کاهش ضایعات زیست‌محیطی: کاهش ۶۴ درصدی ضایعات نساجی در مرحله برش، علاوه بر صرفه‌جویی اقتصادی، به کاهش پسماندهای نساجی و اثرات زیست‌محیطی آن کمک می‌کند.

۳. افزایش بهره‌وری و کاهش زمان تحویل: کاهش ۳۳ تا ۴۸ درصدی زمان محاسبات، امکان برنامه‌ریزی سریع‌تر تولید و کاهش زمان تحویل سفارشات را فراهم می‌کند (al et Abdou, ۲۰۲۴; al et Tsao, ۲۰۲۶).

۴. انعطاف‌پذیری در مواجهه با تغییرات: رویکرد مقاوم ارائه شده، امکان تولید با کیفیت پایدار را حتی در مواجهه با تغییرات پارامترهای فرآیند تولید فراهم می‌کند.

۶.۴. نتیجه‌گیری نهایی

در مجموع، این پژوهش نشان می‌دهد که ترکیب هوشمندانه الگوریتم‌های تکاملی و شبکه‌های عصبی گرافیکی می‌تواند راه‌حل مؤثری برای یکی از چالش‌های اساسی صنعت نساجی، یعنی بهینه‌سازی مصرف مواد و کاهش ضایعات، ارائه دهد. با توجه به فشارهای فزاینده اقتصادی و زیست‌محیطی برای کاهش ضایعات و افزایش بهره‌وری، چنین رویکردهایی می‌توانند نقش کلیدی در تحول دیجیتال و پایداری صنعت نساجی ایفا کنند.

فهرست منابع

۱. Abdou, K., Mohammed, O., Eskandar, G., Ibrahim, A., Matt, P.-A., & Huber, M. F. (2024). Smart nesting :estimating geometrical compatibility in the nesting problem using graph neural networks. *Journal of Intelligent Manufacturing*, 35(6), 2811-2827.
۲. Bäck, T., & Schwefel, H.-P. (1993). (An overview of evolutionary algorithms for parameter optimization. *Evolutionary Computation*, 1(1), 1-23.
۳. Bennell, J. A., & Oliveira, J. F. (2006). (A tutorial on the cutting and packing problems. *European Journal of Operational Research*, 183(1), 1-4.
۴. Chan, K. C. C., Hui, P. C. L., & Yeung, K. W. (1998). (A genetic algorithm approach to the assembly line balancing problem in the garment industry. *International Journal of Clothing Science and Technology*, 10(2), 100-110.
۵. Chen, L. (2020). (Sustainable Material Cutting Optimization Using Deep Q-Networks : A Reinforcement Learning Approach for Resource Efficiency. *ITM Web of Conferences*, 73, 01002.
۶. Chen, R. S., Wu, C. M., & Huang, C. C. (2009). (A grouping genetic algorithm for assembly line balancing with different labor skill levels in the garment industry. *International Journal of Industrial Engineering*, 16(2), 120-131.
۷. Degraeve, Z., & Vandebroek, M. (1998). (A mixed integer programming model for solving a layout problem in the fashion industry. *Management Science*, 44(3), 301-310.
۸. Fogel, L. J., Owens, A. J., & Walsh, M. J. (1966). (Artificial Intelligence through Simulated Evolution. New York :Wiley.
۹. Halimi, M. T., Jaffali, S., Elloumi, S., Khelifi, N., & Trabelsi, A. (2026). (Genetic algorithms for quality improvement in fabric roll cutting problem :a real-world industry case study. *The Journal of The Textile Institute*, 117(8), 1846-1863.
۱۰. Jacobs-Blecha, C., Ammons, J. C., Schutte, A., & Smith, T. (1998). (Cut order planning for apparel manufacturing. *IIE Transactions*, 30(1), 79-90.
۱۱. Lallier, C. (2022). (Deep graph neural networks for 2D nesting efficiency estimation)Doctoral dissertation. (theses.fr).
۱۲. Nascimento, D. B., Neiva De Figueiredo, J., Mayerle, S. F., Nascimento, P. R., & Casali, R. M. (2010). (A state-space solution search method for apparel industry spreading and cutting. *International Journal of Production Economics*, 128(1), 379-392.
۱۳. Neuenfeldt Júnior, A., Siluk, J. C. M., Francescato, M., Stieler, H. H., & Disconzi, J. M. (2023). (The cutting path problem in the cutting and packing problem :A review. *Applied Soft Computing*, 130, 109980.

۱۴. Porter, B). ۱۹۹۸a. (Adaptive evolution strategies for industrial optimization. *Journal of Intelligent Manufacturing*, ۹)۲(, ۱۱۹-۱۲۸.
۱۵. Porter, B). ۱۹۹۸b. (Non-adaptive and adaptive evolution strategies for industrial optimization. *International Journal of Production Research*, ۳۶)۳(, ۷۹۳-۸۱۰.
۱۶. Shang, X., Shen, D., Wang, F.-Y., & Nyberg, T. R). ۲۰۱۹. (A heuristic algorithm for the fabric spreading and cutting problem in apparel factories. *IEEE/CAA Journal of Automatica Sinica*, ۶)۴(, ۹۶۱-۹۶۸.
۱۷. Silva, E., Oliveira, J. F., Oliveira, J. P., & Toledo, F. M. B). ۲۰۱۹. (A two-stage robust optimization for the integrated fabric nesting and cutting-path planning problem under deformation uncertainty. *European Journal of Operational Research*, ۲۷۸)۳(, ۸۷۶-۸۹۱.
۱۸. Tsao, Y.-C., Delicia, M., & Vu, T. L). ۲۰۲۲. (Marker planning problem in the apparel industry :hybrid PSO-based heuristics. *Applied Soft Computing*, ۱۲۳, ۱۰۸۹۳۴.
۱۹. Tsao, Y., Liu, C., Chen, P., & Vu, T). ۲۰۲۶. (Optimizing cut order planning in apparel manufacturing :A particle swarm optimization and genetic algorithm approach. *Applied Soft Computing*, ۱۹۰, ۱۱۴۵۹۰.
۲۰. Ünal, C., & Yüksel, A. D). ۲۰۲۰. (Cut order planning optimisation in the apparel industry. *Fibres and Textiles in Eastern Europe*, ۲۸)۳(, ۸-۱۳.
۲۱. Wong, W. K., Chan, C. K., & Ip, W. H). ۲۰۱۳. (Optimizing marker planning in apparel production using evolutionary strategies and neural networks. In *Optimizing Decision Making in the Apparel Supply Chain Using Artificial Intelligence (AI)* (pp. ۱۰۶-۱۳۱). (Woodhead Publishing.
۲۲. Yang, Y., Guo, L., & Zhang, Z). ۲۰۲۲. (Contour similarity based ۲D bin packing algorithm. *Journal of Industrial and Management Optimization*, ۱۸)۲(, ۱۲۰۵-۱۲۲۲.