

KI-basierte Prozessüberwachung für das Flachstricken

Autoren: Kopelmann, Karl^{1*}; Krüger, Tanja², Waschilewski, Benjamin¹; Anding, Katharina², Seo, Jewon²; Le Xuan, Hung¹; Cherif, Chokri¹

1) Institut für Textilmaschinen und Textile Hochleistungswerkstoff-technik (ITM), TU Dresden

2) Fraunhofer-Institut für Digitale Medientechnologie (IDMT), Ilmenau

Am ITM und IDMT erfolgte im IGF-Projekt 01IF22931N (Entwicklung eines KI-gestützten Inline-Qualitätssicherungssystems zur Optimierung hochflexibler Stricktechnologien (OptiStrick)) die Entwicklung eines modularen, nachrüstbaren, echtzeitfähigen, KI-basierten Monitoring-Systems für die Produktion an Flachstrickmaschinen.

Abstract

Die Sicherstellung einer konstant hohen Produktqualität bei gleichzeitiger Reduktion von Ausschuss zählt zu den zentralen Herausforderungen der Flachstrickerei. Aufgrund der hohen Produktvielfalt und der komplexen Nadel-Garn-Interaktionen existiert bislang kein kosteneffizientes, etabliertes Inline-Überwachungssystem zur Qualitätssicherung. Im Rahmen des IGF-Vorhabens OptiStrick wurde ein KI-gestütztes Inline-Qualitätssicherungssystem entwickelt, das akustische, vibroakustische, tensometrische und optische Sensorik mit Verfahren des maschinellen Lernens verbindet. Auf Grundlage einer statistischen Versuchsplanung wurden multimodale Datensätze aus drei Messkampagnen (Labor- und Produktionsumfeld) erhoben und mit neuronalen Netzen ausgewertet. Akustische und vibroakustische Sensoren erreichten sowohl bei der Klassifikation von Prozessparametern als auch von Einzelnadelfehlern durchgehend hohe Genauigkeiten (> 90 %) und zeigten die höchste Robustheit gegenüber wechselnden Aufnahmebedingungen. Tensometrische Signale eigneten sich unter kontrollierten Bedingungen gut zur Detektion impulsartiger Fehler, verloren jedoch bei veränderter Sensoranbringung deutlich an Leistungsfähigkeit. Der entwickelte Demonstrator wies eine mittlere Genauigkeit für die Parameterklassifikation von etwa 80 % auf und belegte die grundsätzliche Inlinefähigkeit des Ansatzes. Das System ist modular nachrüstbar, wirtschaftlich attraktiv und auf weitere textile Prozesse übertragbar.

Einleitung

Der Flachstrickprozess zeichnet sich durch eine hohe gestalterische Flexibilität aus, ist jedoch aufgrund der komplexen Interaktion einer Vielzahl von Wirkelementen fehleranfällig. Defekte an Nadeln, etwa verbogene Nadelköpfe, abgebrochene Nadelzungen oder -köpfe, sowie zunehmende Verschmutzung durch Faserstaub führen zu Fehlmaschen, Fallmaschen und letztlich zu Ausschuss. Da sich Fehlerbilder in der nachträglichen Warenschau zwar zuverlässig, aber erst zeitversetzt identifizieren lassen, entsteht bis zur Entdeckung eines Defekts fehlerhafte Ware. Eine frühzeitige, bedienerunabhängige Erkennung direkt an der Strickstelle bietet daher erhebliches wirtschaftliches Potenzial.

Inline-Qualitätssicherungssysteme haben sich in der industriellen Fertigung als wirksames Mittel zur Reduktion von Ausschuss und zur Prozessoptimierung etabliert. In der Textilindustrie dominieren dabei kamerabasierte Ansätze (1) zur automatisierten Fehlererkennung, deren Leistungsfähigkeit in den vergangenen Jahren durch den Einsatz von Deep-Learning-Methoden (2–5) erheblich gesteigert werden konnte. Insbesondere convolutional neural networks (CNN) (6) haben sich für die Detektion textiler Flächenfehler als leistungsfähig erwiesen. Gleichwohl sind solche optischen Systeme mit hohen Anschaffungskosten und einem erheblichen Bedarf an Rechenleistung verbunden, was ihre Verbreitung insbesondere in kleinen und mittleren Unternehmen (KMU) hemmt. Einsatz Künstlicher Intelligenz gilt branchenübergreifend als Schlüsseltechnologie zur Digitalisierung von Wertschöpfungsketten (7, 8), wobei die betriebliche Umsetzung von KI-Projekten in der Praxis häufig an Fragen der Robustheit, der Datenverfügbarkeit und der Integrierbarkeit scheitert. Für die Qualitätssicherung erschließen datengetriebene Verfahren zunehmend auch nicht-optische Sensormodalitäten. Das Potenzial akustischer und vibroakustischer Sensorik (9–11) zur Überwachung textiler Prozesse wurde bislang jedoch nur unzureichend systematisch untersucht, obwohl gerade diese Modalitäten eine kostengünstige und nachrüstbare Alternative zur Bildverarbeitung darstellen könnten.

An dieser Stelle setzt das Vorhaben OptiStrick an. Ziel war die Entwicklung eines KI-gestützten Inline-Qualitätssicherungssystems, das qualitätsrelevante Zustände im laufenden Strickprozess erkennt und dabei den Anforderungen von KMU an Wirtschaftlichkeit, Nachrüstbarkeit und Übertragbarkeit gerecht wird (12). Der Fokus lag dabei bewusst nicht auf der nachgelagerten Warenschau, sondern auf der Strickstelle selbst, da hier der überwiegende Teil der Fehler

entsteht. Neben der reinen Fehlerdetektion wurde, abweichend vom ursprünglichen Antrag und auf Wunsch der beteiligten Industriepartner, ein Schwerpunkt auf die Erkennung von Verschleiß- und Versagenszuständen im Sinne einer vorausschauenden Wartung gelegt.

Methoden

Die Entwicklung des OptiStrick-Systems folgte einem iterativen, hypothesengeleiteten Vorgehen, das sich an den Prinzipien der ingenieurwissenschaftlichen Systementwicklung orientierte und in enger Abstimmung mit einem projektbegleitenden Ausschuss (PA) aus Industriepartnern durchgeführt wurde. Der methodische Ablauf lässt sich in fünf aufeinander aufbauende Phasen gliedern: Anforderungsanalyse, Versuchsplanung, Messsystementwicklung, Datenerhebung sowie Algorithmenentwicklung und Systemintegration.

Anforderungsanalyse und Versuchsplanung

Ausgangspunkt bildete eine strukturierte Anforderungserhebung mittels einer Befragung des technischen Personals der beteiligten Unternehmen. Ziel war die Identifikation praxisrelevanter Fehlerbilder, Qualitätsmerkmale und Prozessparameter. Als Untersuchungsgegenstand wurde eine Flachstrickmaschine des Typs Stoll ADF (Abbildung 1) (KARL MAYER Holding SE & Co. KG, Deutschland) mit einer Nadelfeinheit von E7 festgelegt; als Prüfmateriale diente vorrangig Polyester aufgrund seiner weiten industriellen Verbreitung und geringen Flusenbildung. Um die Komplexität beherrschbar zu halten, wurde das Musterprodukt auf ein uniformes, rechteckiges Endlosgestrick mit einheitlicher Bindung beschränkt. Als zentrale, im laufenden Prozess veränderliche Parameter wurden die Kuliertiefe (Nadelsenkerposition) und die Strickgeschwindigkeit bestimmt.



Abbildung 1: Untersuchte Flachstrickmaschine Stoll ADF

Auf dieser Grundlage wurden nach den Regeln der statistischen Versuchsplanung zwei komplementäre Versuchspläne abgeleitet: Versuchsplan A (Parameterstudie) variierte die beiden Prozessparameter in jeweils drei Stufen, während Versuchsplan B (Fehlersimulation) das gezielte Nicht-Austreiben einzelner und paarweiser Nadeln an drei definierten Positionen innerhalb des Nadelbetts (linker, mittlerer und rechter Bereich) zur Simulation von Nadelfehlern vorsah. Ergänzend wurden in Kooperation mit dem Industriepartner Groz-Beckert KG Versuchspläne zur Untersuchung realer Nadel Schäden, wie verbogene Nadelköpfe, abgebrochene Nadelzungen und -köpfe, erstellt. Dieses versuchsplanerische Vorgehen gewährleistete eine reproduzierbare, klar strukturierte und statistisch auswertbare Datengrundlage.

Entwicklung der Messsysteme

Parallel wurden vier Sensormodalitäten konzipiert und experimentell erprobt. Ein zentrales methodisches Prinzip war dabei die synchrone, multimodale Datenerfassung: Sämtliche Sensorsignale wurden über ein zentrales Datenerfassungssystem (Sirius®, DeweSOFT Deutschland GmbH) zeitsynchron aufgezeichnet, um eine konsistente zeitliche Zuordnung und spätere Sensorfusion zu ermöglichen. Zur Unterstützung der Datenannotation wurde ein Triggersystem aus zwei Kurzstanz-Lichtschränken implementiert (Abbildung 2), dass die Interaktion des Strickschlittens mit den Nadeln von der Umkehrfahrt eindeutig abgrenzte und zugleich die Bestimmung der Fahrtrichtung erlaubte.




Abbildung 2: Lichtschranke als Teil des Triggersystems mit optischen Impulsgeber am Strickschlitten

Charakteristisch für den Entwicklungsprozess war die iterative Reduktion auf die wirtschaftlich und technisch sinnvollsten Komponenten. Nicht zielführende Ansätze wurden frühzeitig identifiziert und in Abstimmung mit dem PA verworfen:

- *Akustische/vibroakustische Sensorik*

Es wurden mehrere Mikrofone (MMS212, Microtech Gefell GmbH, Deutschland; M30, Earthworks Inc., USA) sowie ein Richtmikrofon (SE8, sE Electronics International Inc., USA) an der Flachstrickmaschine montiert und zudem die bereits in der Maschine verbauten Piezo-/Körperschallsensoren betrachtet.

- *Tensometrische Messtechnik*

Für die tensometrische Messtechnik wurden zwei Positionen (beweglich am Fadenführer, stationär unterhalb des Fournisseurs) sowie zwei Systeme evaluiert: ein dedizierter 3-Rollen-Fadenzugkraftsensor (M120/SA310, Tensometric Messtechnik GmbH, Deutschland) und ein herstellerseitig modifizierter Fournisseur (EFS 920, Memminger-IRO GmbH, Deutschland).

- *Optische Messtechnik*

Es wurde eine Hochgeschwindigkeitskamera (DS-CAM 1100m, DEWESoft Deutschland GmbH) inklusiver einer LED-Hochleistungsbeleuchtung auf dem Strickschlitten montiert. Auf Basis des Nyquist-Shannon-Abtasttheorems und einer Nadelpassrate von 276 Nadeln/s wurde eine erforderliche Bildrate von mindestens 552 fps errechnet.

Datenerhebung

Die Datenbasis wurde in drei Messkampagnen erhoben: zwei unter kontrollierten Laborbedingungen (R1, R2) und eine im produktionsnahen Umfeld beim Partner Groz-Beckert KG (R3), in der auch reale Schadensereignisse an Nadeln aufgezeichnet werden konnten. Insgesamt wurden über alle Messkampagnen hinweg mehr als 8 Stunden Aufnahmematerial erfasst (Tabelle 1), wobei die einzelnen Aufnahmen 60 s umfassten. Die kontinuierlichen Signale wurden auf Basis einzelner Schlittenbewegungen, abgegrenzt durch die Lichtschrankensignale, in Segmente unterteilt und anhand der Prozessparameter mit Labels versehen.

Tabelle 1: Übersicht über die Datengrundlage der Untersuchungen mit Anzahl der untersuchten Klassen und den aufgezeichneten Klassen.

Messkampagne	Experiment	# Klassen	# Aufnahmen	# Segmente
R1	Parameter	8	120	6.824
R1	Nadelfehler	6	18	2.052
R2	Parameter	8	52	8.488
R2	Nadelfehler	9	9	1.401
R3	Parameter	9	55	1.141
R3	Nadelfehler	9	23	1.403
R3	Spezielle Nadelfehler (Verbogene Nadeln)	3	9	837

Signalverarbeitung, Modellbildung und Validierung

Die akustischen und vibroakustischen Signale wurden auf eine einheitliche Abtastrate von 32 kHz resampelt und anschließend in Mel-Spektrogramme überführt (128 Frequenzbänder, 64-ms-Fenster, 32-ms-Schrittweite). Für die spektrogrammbasierten Modalitäten kamen 2D CNNs zum Einsatz, während die Fadenzugkraftdaten mittels zeitreihen-basierter Modelle ausgewertet wurden. Im Verlauf der iterativen Algorithmenentwicklung wurden verschiedene Verfahren (DNN, CNN, SVM, XGBoost) trainiert und für unterschiedliche Klassifikationsaufgaben anhand von Sensitivität, Spezifität und AUC bewertet.

Ein methodisch zentraler Aspekt war die realitätsnahe Validierung. Um zu vermeiden, dass die statistische Abhängigkeit von Segmenten derselben Aufnahme die Ergebnisse verzerrt, wurde vorrangig eine aufnahmebasierte

Kreuzvalidierung (GroupKFold) eingesetzt, bei der alle Segmente einer Aufnahme geschlossen in derselben Bewertungsgruppe verbleiben. Darüber hinaus wurde gezielt die Domänenverschiebung zwischen Messkampagnen untersucht, indem Modelle auf einer Kampagne trainiert und auf einer anderen getestet wurden. Aufbauend darauf wurden verschiedene Strategien der multimodalen Datenfusion untersucht, um die Robustheit gegenüber veränderten Aufnahmebedingungen zu erhöhen. Hierbei wurden sowohl eine entscheidungsbasierte Late Fusion als auch eine merkmalsbasierte Feature Fusion evaluiert.

Ergebnisse

Selektion des Messsystems

Bei der Untersuchung des akustischen/vibroakustischen Messsystems zeigt sich, dass das gerichtete SE8 auch bei starkem Störschall (Lüftung, benachbarte Textilmaschinen) konsistent gute Signale lieferte (Abbildung 3). Weitere Mikrofone im Innenraum der Maschine darüber hinaus boten dagegen keinen weiteren Mehrwert. Da die integrierten Piezo-Schocksensoren eine hohe Sensitivität gegenüber prozessrelevanten Ereignissen zeigten und zusätzliche Mikrofone keinen wesentlichen Informationsgewinn lieferten, wurde das Messsystem auf ein Richtmikrofon und die bereits vorhandenen Schocksensoren reduziert.



Abbildung 3: Montiertes Richtmikrofon SE8 (roter Kreis) über der Strickstelle an der Maschine

Unter den untersuchten tensometrischen Sensoren erwies sich das dedizierte System dem modifizierten Fournisseur als überlegen. Es lieferte die höhere Signalauflösung, in der einzelne Maschenabschläge und simulierte Nadelfehler unmittelbar erkennbar waren. Dennoch waren gröbere Trends auch in den Messungen des Fournisseurs erkennbar, sodass bei einer vorhandenen CAN-Schnittstelle die Daten gut ergänzt werden können. Als geeignete Position wurde letztlich die statische Position am Gestell oberhalb der Strickstelle evaluiert (Abbildung 4). Eine potentielle Montage am Fadenführer erwies sich als komplexe und nicht kosteneffizient.



Abbildung 4: Modifizierter Fournisseur und 3-Rollen-Fadenzugkraftsensor statisch montiert oberhalb der Maschine.

Das optische System (Abbildung 5) wurde letztlich nicht in das Gesamtsystem integriert. In der Erprobung erwies es sich aufgrund von Abschattungen durch Wirkelemente, unzureichende Ausleuchtung und einer real erreichbaren Bildrate von nur 400 fps als unzureichend. Die notwendige Demontage der Nadelbürste bedeutete extreme Einschränkungen für die Produktgestaltung und war damit nicht praxistauglich. Der hohe Rechenaufwand für die Aufzeichnung und Auswertung der Bilddaten wurde ebenfalls negativ bewertet, speziell in Bezug auf die Kosteneffizienz.




Abbildung 5: links: Positionierung der Kamera in der Maschine; rechts: Aufnahme der Hochgeschwindigkeitskamera mit gut erkennbarer fehlender Nadel.

Das finale System optimierte die Anzahl der Sensoren und eingesetzten Messsysteme hinsichtlich der besten Messqualität bei möglichst geringen Kosten. Die notwendigen Komponenten für das finale System sind in Tabelle 2 aufgelistet.

Tabelle 2: Übersicht über die final verwendeten Sensoren für Inline-Überwachungssystem

Sensoren	Anzahl	Stückpreis
Mikrofon SE8	1	200 €
Piezo-Schocksensor	2 pro Nadelbett	Bereits vorhanden
Fadenzugkraftsensor	1 pro Fadensystem	300 €
Fournisseur	1 pro Fadensystem	Bereits vorhanden
DAQ-System	1	3000 €
Computer	1	2000 €

Klassifikation von Prozessparametern

Innerhalb einer Messkampagne erzielten insbesondere die akustischen und vibroakustischen Sensoren eine sehr hohe Klassifikationsleistung (Tabelle 3). Das Fadenzugsignal (FZK) lieferte relevante Informationen, blieb hinsichtlich der Trennschärfe jedoch deutlich zurück.

Tabelle 3: Vergleich der Klassifikationsgenauigkeit für die Parametererkennung innerhalb der Messkampagnen (R1–R3) für verschiedene Sensorsysteme.

Sensor	R1 (8 Kl.)	R2 (8 Kl.)	R3 (9 Kl.)
SE8	97,1 ± 0,5	90,1 ± 6,4	94,3 ± 2,0
MMS212-L	96,3 ± 1,2	98,9 ± 0,2	91,4 ± 4,1
MMS212-R	97,3 ± 0,9	94,8 ± 5,8	92,5 ± 4,1
Piezo1	91,2 ± 2,2	91,3 ± 6,1	97,0 ± 1,2
Piezo2	95,4 ± 1,4	97,9 ± 0,5	95,7 ± 1,5
FZK	82,6 ± 3,2	69,9 ± 7,3	66,8 ± 8,1
Fournisseur	—	—	94,0 ± 5,8

Die Analyse der Konfusionsmatrizen zeigte, dass Fehlklassifikationen überwiegend innerhalb derselben Geschwindigkeitsklasse auftraten und primär feine Unterschiede in der Kuliertiefe betrafen. Die Prozessgeschwindigkeit prägt das Signal deutlich stärker. Besonders relevant ist, dass die Modellarchitektur ohne strukturelle Anpassung auch auf die produktionsnahen Daten (R3) übertragbar war und dort ein mit dem Labor vergleichbares Niveau erreichte.

Klassifikation von Nadelfehlern

Bei einer vereinheitlichten 3-Klassen-Problemstellung erzielten die akustischen und vibroakustischen Sensoren über alle Kampagnen hinweg durchgehend hohe Genauigkeiten (Tabelle 4). Der tensometrische Sensor erreichte in den Laborkampagnen ebenfalls sehr hohe Werte (Abbildung 6), fiel in der produktionsnahen Kampagne R3 jedoch auf das Zufallsniveau ab.




Abbildung 6: Auf dem mit dem tensometrischen Sensor gemessenen beispielhaften, normierten Verlauf der Fadenzugkraft ist im Verlauf ein Knick erkennbar, induziert durch eine fehlende Nadel. Die Signale der Lichtschranken links (grün) und rechts (orange) sind ebenfalls zu sehen.

Tabelle 4: Klassifikationsgenauigkeit für die Nadelfehlererkennung.

Sensor	R1	R2	R3
SE8	93,2 ± 3,2	99,3 ± 0,5	97,5 ± 1,7
MMS212-L	93,9 ± 0,7	93,3 ± 2,9	96,6 ± 2,2
MMS212-R	94,4 ± 1,7	93,6 ± 4,1	97,5 ± 2,3
Piezo1	94,8 ± 1,1	94,2 ± 2,2	95,3 ± 1,1
Piezo2	94,2 ± 1,6	95,1 ± 2,7	77,8 ± 24,8
FZK	98,3 ± 1,8	95,8 ± 3,2	33,1 ± 5,5
Fournisseur	—	—	94,2 ± 3,0

Der Leistungsabfall des FZK-Sensors in R3 ließ sich auf die veränderte Sensoranbringung zurückführen: Während der Sensor im Labor mittig oberhalb der Maschine positioniert war, erfolgte die Integration im Produktionsumfeld seitlich (Abbildung 7), was die charakteristischen impulsartigen Signalverläufe abschwächte.



Abbildung 7: Die untersuchten Flachstrickmaschinen für die Messkampagnen im Labor- (links) und Produktionsumfeld (rechts) mit visualisiertem Fadenlauf (rote Pfeile).

Domänenverschiebung und Sensorfusion

Bei der kampagnenübergreifenden Anwendung sank die Klassifikationsleistung deutlich. Die extrahierten Merkmale bildeten kampagnenspezifische Cluster. Für die Parameterklassifikation blieben die akustischen Sensoren dennoch oberhalb des Zufallsniveaus, während der FZK-Sensor nahezu vollständig versagte. Bei der Nadelfehlererkennung zeigte sich ein differenzierteres Bild: Hier erreichte der tensometrische Sensor beim Transfer teils die besten Ergebnisse, da er

charakteristische impulsartige Fehlermuster erfasst, die auch unter veränderten Bedingungen stabil bleiben.

Die Sensorfusion erwies sich vor allem unter nicht-stationären Bedingungen als vorteilhaft (Tabelle 5). Während unter stabilen Laborbedingungen der Zusatznutzen begrenzt blieb, verbesserte die Kombination komplementärer Modalitäten in R3 die Robustheit spürbar (Late Fusion und Feature Fusion erreichten hier über 99 %).

Tabelle 5: Klassifikationsgenauigkeit für die Prozessparametererkennung in R1 und R3 unter Verwendung verschiedener Fusionsstrategien.

Modell	R1 (in %)	R3 (in %)
SE8 (single)	98,8 ± 0,1	97,7 ± 1,3
FZK (single)	86,0 ± 2,0	78,5 ± 3,5
Late Fusion (w = 0,5)	98,1 ± 0,6	99,4 ± 0,5
Feature Fusion – Linear SVM	99,2 ± 0,3	99,4 ± 0,9

Verbogene Nadeln, Verschleiß und Demonstrator

Bei der Erkennung verbogener Nadeln (nicht-impulsartiges Fehlerbild) erreichten die akustischen Sensoren und der Fournisseur Genauigkeiten von über 95 %, während der FZK-Sensor mit 52,9 % nur knapp über dem Zufallsniveau lag. Langsam voranschreitender Verschleiß (etwa durch Verschmutzung) konnte hingegen nicht belastbar detektiert werden: Selbst bei nahezu abgeschalteter Maschinenreinigung trat innerhalb der Versuchsdauer keine messbare Verschmutzung auf, wozu auch die geringe Flusenleistung des Polyestergarns sowie die vergleichsweise kurze Dauer der Messkampagnen beitrug. Die finalen Versagenszustände (Brüche einzelner Strickelemente) waren dagegen gut erkennbar.

Der integrierte Demonstrator führte Datenakquise, Merkmalsextraktion und Klassifikation in einer durchgängigen Pipeline zusammen und wurde am ITM unter praxisnahen Bedingungen validiert. Nach einem Nachtraining auf die konkrete Einsatzumgebung erreichte er eine mittlere Klassifikationsgenauigkeit von etwa 80 % und belegte damit die grundsätzliche Inlinefähigkeit. Eine grafische Benutzeroberfläche (Abbildung 8) ermöglichte die Auswahl der Sensormodelle und die Visualisierung der Ergebnisse.



Abbildung 8: Dashboard des Funktionsdemonstrators, dass die laufende Parameterklassifikation visualisiert

Diskussion

Die Ergebnisse belegen, dass akustische und vibroakustische Sensorik eine robuste und kosteneffiziente Alternative zu kamerabasierten Systemen darstellt. Über alle Messkampagnen, einschließlich des produktionsnahen Umfelds, lieferten diese Modalitäten sowohl bei der Parameter- als auch bei der Nadelfehlerklassifikation durchgehend hohe Genauigkeiten. Besonders bemerkenswert ist die Übertragbarkeit der Modellarchitektur vom Labor auf reale Produktionsbedingungen ohne strukturelle Anpassung.

Ein differenziertes Bild ergibt sich für die tensometrische Sensorik: Sie eignet sich unter kontrollierten Bedingungen hervorragend zur Detektion impulsartiger Einzelnadelfehler, ist jedoch stark von der konkreten Sensoranbringung und der damit verbundenen Krafteinleitung abhängig. Bei veränderter Positionierung oder nicht-impulsartigen Fehlerbildern (verbogene Nadeln) bricht ihre Leistungsfähigkeit ein. Daraus folgt eine aufgabenspezifische Einordnung der Sensormodalitäten: Keine einzelne Sensorik ist für alle Anwendungsfälle gleichermaßen geeignet.

Die zentrale verbleibende Herausforderung ist die Domänenverschiebung. Die deutlichen Leistungseinbußen beim kampagnenübergreifenden Transfer zeigen, dass eine zuverlässige Generalisierung über unterschiedliche Aufnahmeumgebungen hinweg ohne Domänenanpassung, Nachtraining oder zusätzliche repräsentative Trainingsdaten nur eingeschränkt möglich ist. Sensorfusion kann diese Robustheit unter variierenden Bedingungen teilweise erhöhen, ihr Nutzen hängt jedoch maßgeblich von einer anwendungs-

spezifischen Gewichtung der Modalitäten ab. Eine wesentliche Einschränkung stellt zudem die begrenzte Anzahl unabhängiger Aufnahmesitzungen dar, die die statistische Aussagekraft hinsichtlich der Robustheit limitiert.

Für die Detektion schleichenden Verschleißes zeigte sich, dass diese im Gegensatz zu akuten Defekten nicht kurzfristig simuliert werden kann, sondern spezifische Langzeitversuche mit kontinuierlicher Datenerfassung und definierten Referenzzuständen erfordert.

Key Takeaway: Akustische Sensorik in Kombination mit KI-gestützter Datenanalyse bietet ein hohes Potenzial für die Digitalisierung der Qualitätssicherung im Flachstrickprozess. Die zentrale Hürde für den industriellen Einsatz ist weniger die grundsätzliche Erkennungsleistung als vielmehr die Robustheit gegenüber Domänenverschiebungen.

Aus wirtschaftlicher Sicht zeigt die Bewertung, dass ein funktionsfähiger Basisausbau des OptiStrick-Systems gemäß Tabelle 2 mit marktverfügbarer Sensorik und Datenerfassungstechnik bereits für ca. 6.160 € je Flachstrickmaschine mit zwei Nadelbetten und drei überwachten Garnen realisierbar ist. Damit liegt der aktuelle Prototypenstand noch oberhalb des ursprünglich angestrebten Zielkorridors von 1.500 €, bildet jedoch eine technisch robuste Ausgangskonfiguration für die industrielle Weiterentwicklung. Zusätzlich ist für eine betriebssichere industrielle Anwendung ein weiterführender Entwicklungsaufwand in der Größenordnung eines weiteren Projektjahres (Personalkosten ca. 90.000 €) einzuplanen. Angesichts einer Ausschussrate von bis zu 10 % bei komplexen technischen Gestriken ist eine Amortisation daher erst mittelfristig zu erwarten. Perspektivisch lassen sich die Kosten jedoch deutlich senken, etwa durch den eines Mikrocomputer (ca. 350 €) nach abgeschlossenem KI-Training oder durch reine akustische Setups mit kostengünstigen Körperschallsensoren (ca. 15 € pro Stück).

Fazit und Ausblick

Das Vorhaben OptiStrick hat mit der Entwicklung des KI-gestützten Inline-Qualitätssicherungssystem für den Flachstrickprozess einen wichtigen Schritt zur Digitalisierung und Automatisierung der Qualitätssicherung in der Strickerei geleistet. Durch die Kombination bereits vorhandener Sensoren, wie Fournisseur und werkseitige Schocksensoren, mit einem zusätzlichen Richtmikrofon lässt sich mit vergleichsweise geringem Aufwand ein leistungsfähiges Überwachungssystem realisieren, das Nadeldefekte und daraus resultierende Gestrick-

veränderungen frühzeitig und bedienerunabhängig erkennt. Wissenschaftlich wurden die multimodale Verknüpfung tensometrischer, vibroakustischer und akustischer Sensorik, die Entwicklung geeigneter KI-Modelle, sowie die zuverlässige Klassifikation von Prozessparametern und spezifischen Nadelfehlern erfolgreich demonstriert.

Für zukünftige Arbeiten ergeben sich drei zentrale Handlungsfelder. Erstens sollte die Datengrundlage unter unterschiedlichen realen Einsatzbedingungen deutlich erweitert werden, um die Generalisierungsfähigkeit statistisch abzusichern. Zweitens sind gezielt Methoden zur Verbesserung der Robustheit, etwa Domänenanpassung, angepasste Vorverarbeitung und optimierte Fusionsstrategien, zu untersuchen, um Domänenverschiebungen zu kompensieren. Drittens erfordert die Erkennung langsam fortschreitender Verschleißmechanismen dedizierte Langzeitversuche mit kontinuierlicher Datenerfassung; für die instrumentierte Erfassung der Nadelbeanspruchung erscheinen zudem miniaturisierte Dehnungsmessstreifen direkt an der Nadel als vielversprechender Ansatz.

Langfristig ist das Funktionsprinzip auf weitere textile Prozesse, etwa Weben, Sticken oder Nähen, übertragbar. Mit zunehmender Betriebsdauer und wachsender Datenbasis verbessern sich die KI-Modelle kontinuierlich, und die absehbaren Fortschritte im Bereich der KI-Soft- und -Hardware werden die Implementierung solcher Systeme wirtschaftlich zunehmend attraktiv machen, insbesondere auch als nachrüstbare, kosteneffiziente Lösungen für bestehende Produktionsanlagen in KMU.

Danksagung

Das IGF-Vorhaben 01IF22931N der Forschungsvereinigung Forschungskuratorium Textil e.V., Reinhardtstr. 12-14, 10117 Berlin wurde über das DLR im Rahmen des Programms zur Förderung der industriellen Gemeinschaftsforschung und -entwicklung (IGF) vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Die Autoren danken den genannten Institutionen für die Bereitstellung der finanziellen Mittel. Der Forschungsbericht und weiterführende Informationen sind am Institut für Textilmaschinen und Textile Hochleistungswerkstofftechnik der TU Dresden, sowie dem Fraunhofer-Institut für Digitale Medientechnologie erhältlich.

Kontakt

hung.le_xuan@tu-dresden.de

<https://tu-dresden.de/ing/maschinenwesen/itm>

Technische Universität Dresden

Fakultät Maschinenwesen

Institut für Textilmaschinen und Textile Hochleistungswerkstofftechnik (ITM)

01062 Dresden

katharina.anding@idmt.fraunhofer.de

<https://www.idmt.fraunhofer.de/>

Fraunhofer IDMT

Ehrenbergstraße 31

98693 Ilmenau

Literatur

1. KAHRAMAN, Y. und A. DURMUŞOĞLU. Deep learning-based fabric defect detection: A review [online]. *Textile Research Journal*, 2023, **93**(5-6), 1485-1503. ISSN 0040-5175. Verfügbar unter: doi:10.1177/00405175221130773
2. METIN, A. und T.T. BILGIN. Automated machine learning for fabric quality prediction: a comparative analysis [online]. *PeerJ. Computer science*, 2024, **10**, e2188. Verfügbar unter: doi:10.7717/peerj-cs.2188
3. WUEST, T., D. WEIMER, C. IRGENS und K.-D. THOBEN. Machine learning in manufacturing: advantages, challenges, and applications [online]. *Production & Manufacturing Research*, 2016, **4**(1), 23-45. Verfügbar unter: doi:10.1080/21693277.2016.1192517
4. KHUSHEEF, A.S., M. SHAHBAZI und R. HASHEMI. Deep Learning-Based Multi-Sensor Fusion for Process Monitoring: Application to Fused Deposition Modeling [online]. *Arabian Journal for Science and Engineering*, 2024, **49**(8), 10501-10522. ISSN 2193-567X. Verfügbar unter: doi:10.1007/s13369-023-08340-4
5. SUN, A., S. CHE, J. FU und K. WANG. Multi-sensor information fusion technologies and applications: a review [online]. *The International Journal of Advanced Manufacturing Technology*, 2026, **144**(1-2), 177-192. ISSN 0268-3768. Verfügbar unter: doi:10.1007/s00170-026-17965-2
6. WEI, B., K. HAO, X. TANG und Y. DING. A new method using the convolutional neural network with compressive sensing for fabric defect classification based on small sample sizes [online]. *Textile Research Journal*, 2019, **89**(17), 3539-3555. ISSN 0040-5175. Verfügbar unter: doi:10.1177/0040517518813656
7. HEYEN, C. Applying AI for Future Business Models in the Textile and Fashion Value Chain [online]. *International Journal for Research in Applied Science and Engineering Technology*, 2025, **13**(3), 378-386. Verfügbar unter: doi:10.22214/ijraset.2025.67255
8. YILDIRIM, P., D. BIRANT und T. ALPYILDIZ. Data mining and machine learning in textile industry [online]. *WIREs Data Mining and Knowledge Discovery*, 2018, **8**(1). ISSN 1942-4787. Verfügbar unter: doi:10.1002/widm.1228
9. KOTHURU, A., S.P. NOOKA und R. LIU. Application of audible sound signals for tool wear monitoring using machine learning techniques in end milling [online]. *The International Journal of Advanced Manufacturing Technology*, 2018,

95(9-12), 3797-3808. ISSN 0268-3768. Verfügbar unter: doi:10.1007/s00170-017-1460-1

10. FATOBA, O.S. und T.-C. JEN. Acoustic-Based In-Situ Monitoring of Additive Manufacturing Fabrication: A Review. In: *2023 14th International Conference on Mechanical and Intelligent Manufacturing Technologies (ICMIMT)*: IEEE, 2023, S. 250-256. ISBN 979-8-3503-1309-3.

11. CIABURRO, G. und G. IANNACE. Machine-Learning-Based Methods for Acoustic Emission Testing: A Review [online]. *Applied Sciences*, 2022, **12**(20), 10476. Verfügbar unter: doi:10.3390/app122010476

12. WESTENBERGER, J., K. SCHULER und D. SCHLEGEL. Failure of AI projects: understanding the critical factors [online]. *Procedia Computer Science*, 2022, **196**, 69-76. ISSN 18770509. Verfügbar unter: doi:10.1016/j.procs.2021.11.074