

# 光学式表面検査の自動化と運用を AIで簡素化する方法

By Dr.-Ing. Jochen G. Koenig, managing director, Schenk Vision

## 概要

フィルム、不織布、紙、およびそれらの加工品やラミネート製品の自動光学検査(AOI)は、ますます強力で汎用的になってきていますが、運用・常駐するエンジニアの人数が減少するにつれ、日常業務への導入が困難になる場合があります。そのため、AOIメーカーにおいては、AOIシステムの日常的な運用を本質的にハンズオフにし、初期導入を可能な限り簡素化するという目標に向けて、ツールや手法の開発に注力することが重要となっています。これには、光量調整、検出レベル、欠陥分類などのタスクを自動化する様々な形態の人工知能(AI)が使用されています。本稿では、これらの機能の一般的な仕組みと、その活用事例を紹介します。

## AOIシステムを最適化するための3つのステップ

自動光学式検査装置(AOI)が設置されると、光学系の調整を行います。最新のAOIは、通常、コントラストに敏感な光学系や歪みに敏感な光学系など、複数の光学系を備えています。複数光学系で取得した画像を使用することで、検出能力だけでなく、異なるタイプの欠陥を適切に区別する能力(classification)が大幅に向上します。しかしながら、これを実現するためには、複数の光学系条件をそれぞれの製品に合わせて最適化し、さらに多くの欠陥属性を使用して分類ルールを開発する必要があります。

検査対象製品への展開・導入プロセスは、基本的に3つのステップに分けることができます。

- 各光学系の光量とカメラゲインを調整し、欠陥検出のためのコントラストを最適化する。
- 欠陥を捉えるための妥当なトリガーレベル(閾値)を決定する。
- 複数光学系で撮影した欠陥画像に基づいた分類を行う。


## 材料に対する自動適応

最初のステップとして、複数光学系で最適なコントラストが得られるように、カメラのゲインや照明の出力レベルを設定する必要があります。これは一般的には簡単な作業ですが、光学系の構成によっては少し厄介な作業となる場合があります。しかしながら、最適化は通常、反復プロセスであり、オペレーターやメンテナンス担当者が対応可能な手順を策定することができます。簡単な手順として以下のようなものがあります。


- 最初の光学系の平均輝度を決定する。
- 暗すぎる場合は、光量またはカメラゲインを増加させ、明るすぎる場合は、それに応じて減少させる。
- 再度、平均輝度を決定する。目標通りであれば次の光学系のステップ1へ、そうでなければステップ2へ進む。

十分に簡単な手順ですが、実際にはAOIシステムの専門家は、全体的な画像システムのノイズや光源など、より多くの入力を確認します。特に不織布またはテクスチャー材料のような複数の照明を必要とする検査では、それぞれの照明のバランスを適切に調整する必要があります。

そこで、人工知能の最も古典的な形式のひとつが役に立ちます(図1参照)。



不適切な光量バランス  
→ 材料ノイズに欠陥が埋もれる



自動的に最適化された  
光量バランス  
→ 欠陥が確実に検出される

図1: 材料への適応(不織布上の毛髪)

この手順は、単純なエキスパートシステムによって管理されるインクリメンタルな制御アルゴリズムです。このシステムは一連の手順に従い、プログラムされた決定を下すことで画像を調整する「エキスパート」の役割を担います。

AIは、人間の専門家よりもはるかに速く、人間が陥りそうなミスリスクもなく、このタスクを実行することができるのです。実際、手作業で実施していた同社の熟練エンジニアも、数秒で決着がつく「材料への自動調整」の正確さとスピードに感心しています。

## インテリジェントな欠陥検出閾値の調整

次のステップでは、異常（欠陥）の検出をシステムが処理可能なレベルに調整します（図2参照）。ほとんど全ての材料は、何らかの形の「材料ノイズ」を示します。これは、表面の粗さ、くもり、エンボス加工などのパターンによって生じる材料の微細な変動として説明できます。不織布の場合、これらはかなり大きな面積の変動になることもありますが、特定の制限内ではその材料にとって正常です。

これらの閾値を調整するための通常の方法は、「材料ノイズ」を見て、安全なレベルに閾値を設定することです。しかし、プロセスによっては、1つの製品の中で、あるいは特定の製品の実行ごとに、ノイズが変化することがあります。従来、AOIメーカーは、このようなノイズの発生を抑えるために単一の「感度調整ツマミ」を提供することがありました。これは便利な反面、一度ノイズの大きい材料を検査するためにこのツマミで感度を下げると、ノイズの小さい材料を検査するときに、元の感度に戻ることはほとんどありません。

必要なことは、材料ノイズを継続的に観察し、システムの欠陥処理機能が最適に動作するように検出閾値を適応させることであり、最適な検出感度を自動的かつ継続的に決定するシステムインテリジェンスです。

これは、インテリジェントなノイズレベル測定とシステム負荷監視を組み合わせることで、システム自身がその限界点を学習することで実現されています。ここでとった戦略は、基本的には、“過負荷にならない程度に、できるだけ多くの異常（欠陥）を調べるようにシステムを追い込む方法”です。最大64個のプロセッサコアを持つ最新のメインプロセッサは、数年前では考えられなかったような画像処理と欠陥分類の能力を発揮します。

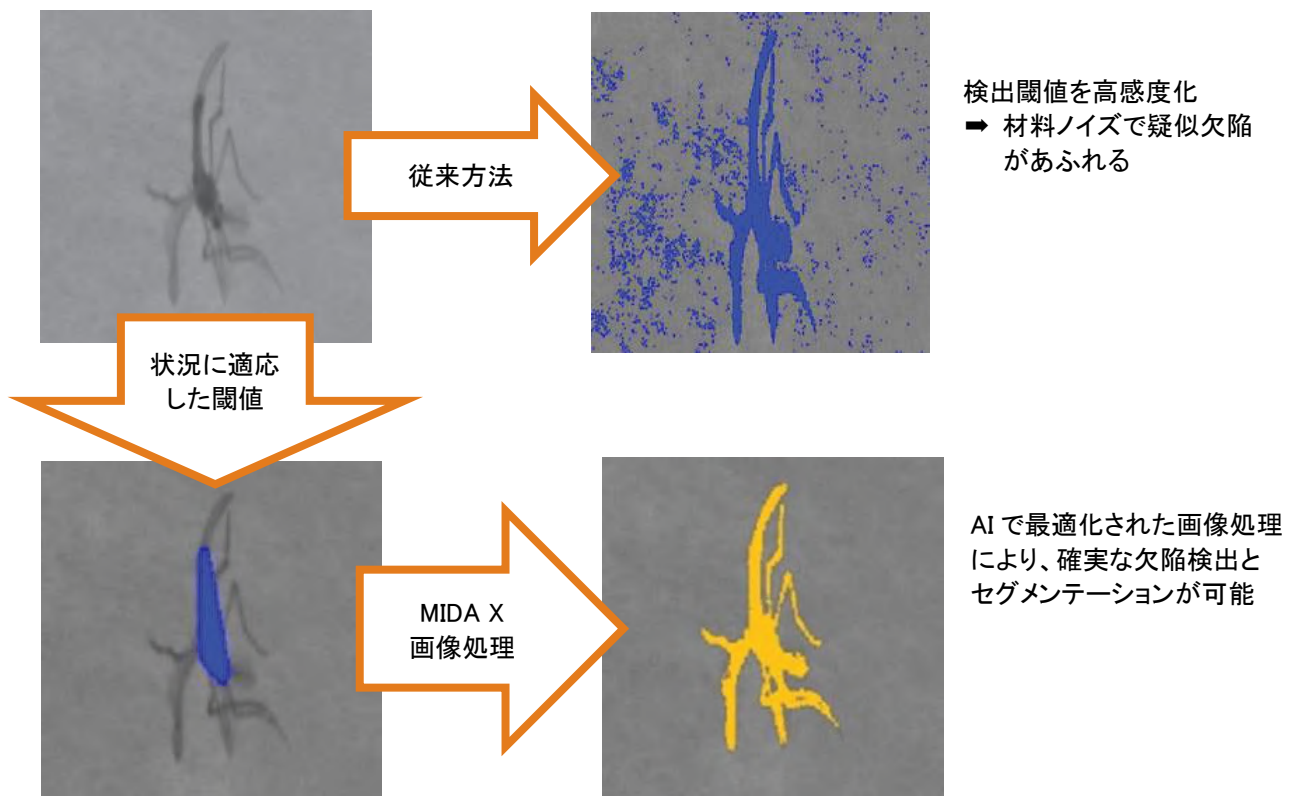


図2: 「状況に適応した閾値」と「MIDA X 画像処理」

## 欠陥検出や分類を目的とした人工知能(機械学習):

AIが自動検査に最も大きな影響を与えたのは、実際の欠陥のセグメンテーションと分類であることは間違いありません。画像(映像)内の物体を分離し、素早く分類する物体認識の分野では、多くの新しい研究が生まれています。例えば、自動運転車の場合、「見ているもの」を素早く識別し、車に対する物体の動きを追跡する必要があります。

画像処理の世界では、画像内の物体を分離する機能をセグメンテーションと呼びます。画像処理では、画像の勾配(変化率)に対して1つまたは複数の閾値を設定した単純なエッジ検出フィルタを用いて、物体の輪郭を特定する方法が長年使われており、信頼を得ています。この方法は、周囲と比較して高いコントラストを持つ物体に対して有効です。そうではなく、物体が徐々に背景にフェードインする場合、これらの方法では、物体全体を捉えられず、コントラストの高い断片的な部分しか認識できない可能性があります。例えば、図2(左上)の昆虫を例にとると、胴体は検出できても、脚や羽は見逃してしまうこととなります(左下)。この分類では、昆虫であることを識別するのは難しいでしょう。

従来、適切な画像フィルタリングやセグメンテーションのアルゴリズムを開発するためには、経験豊富な画像処理エンジニアが必要であり、多くの時間がかかる可能性がありました。今日では、AIがその役割を担っています。面倒な作業の多くは、私たちの手を離れて行われます。これは、セグメンテーションの望ましい結果が何であるかをAIシステムに伝える方法として、画像内に捉えられた欠陥の輪郭を定義するだけで機能します。するとAIは文字通り何百、何千もの異なる画像処理方法で画像を処理し、最適な方法を特定します。

## 3つの物体認識アルゴリズム

分類された欠陥画像の適切なライブラリは、分類をさらに向上させるための基盤となります。物体認識アルゴリズムには、基本的に3つのグループがあります。決定木(Decision Tree)、ニューラルネットワーク(Neural Networks)、サポートベクターマシン(SVM: Support Vector Machine)です。

**決定木(Decision Tree)**とは、基本的には道の分岐のセットであり、「真/偽」の質問に対する答えによって、どの分岐に進むかが決定されます。最終的に、欠陥は決定木の「葉」のひとつに到達することになります。

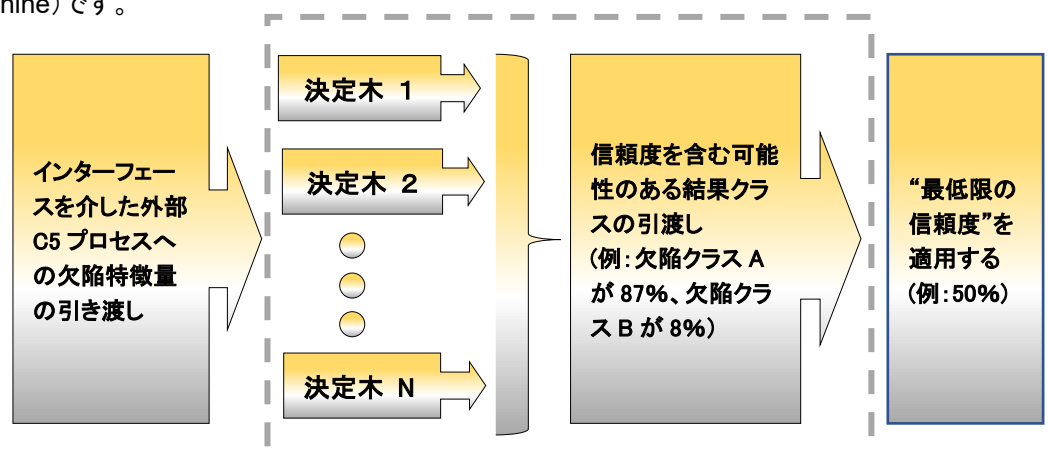


図3: ブースティング手法を伴うC5.0欠陥分類アルゴリズム

その結果、図2(右下)のMIDA Xの画像のように、高度な画像セグメンテーションが可能になりました。このような特に難しいアプリケーションでは、ビジョンシステムの顧客に提供している膨大なクラウドコンピューティングパワーが必要になる場合があります。

さて、これで欠陥のセグメンテーションがうまくいったので、最後のステップは欠陥の分類です。分類とは、検査装置が撮影した1枚または複数枚の画像から、欠陥の種類を自動的に判断することです。例えば、材料表面にある粒子と材料に埋め込まれた粒子(プラスチックフィルムの中のゲルなど)を区別するような場合です。

これを行う古典的な方法は、検出された欠陥(特徴)を表す数値について深い知識を持つ経験豊富なアプリケーションエンジニアが、手書きでルールを書くことです。明らかに異なる外観を持つ1枚の画像であれば、これはうまく機能します。しかし、複数の画像を使用する場合、その作業は非常に複雑になり、最適な結果を得ることが難しくなります。

数十年にわたり、この作業を簡略化するために、さまざまなフレーバーの自動分類器がAOIシステムに実装されてきました。どの機械学習技術を使っても、結果を出すには、私たちが探しているものを全て「学習」させる必要があります。つまり、様々なカテゴリに分類される多数の欠陥画像を収集する必要があります。システムが物理的に設置されると、最初は材料そのものと異なる全てのものを捉えるように設定されます。その後、ユーザーは捉えられた欠陥画像を確認し、類似の欠陥を個々のバケットに収集します。この作業は数時間で終わることもありますが、実際の欠陥発生率や製品の稼働率に大きく依存します。

このアルゴリズムを拡張したものが、C5.0 アルゴリズムです。これは基本的に、その欠陥をどのカテゴリに分類するかについて、どの程度確信を持っているかを記述するものです。例えば、70%の確率で「ゲル」、30%の確率で「カーボン」と記述することができます。

特定の C5.0 ツリーが出す判定に関連する確率が分かり、ブースティングという手法を適用できるようになりました（図 3 参照）。決定木は、例えばどの数値特徴を最初に見るかによって結果が多少異なるため、C5.0 エンジンに複数の決定木を作成し、それらの確率を組み合わせることができます。これは要するに、複数人で欠陥を見て、判断をくだすようなものです。その結果、欠陥クラス確率の組み合わせが得られ、どれが最も高い確率かで欠陥を分類することができます。例えば 60%という閾値を設定し、60%を超える場合のみ欠陥クラス判定を行い、それ以外は“unspecified(未確定)”とすることも可能です。これにより、明確な判定が出たときだけ結果を出すように AI システムに指示することができます。これを“決選投票”と呼びます。

産業用アプリケーションにおける決定木ベースの自動分類器の利点の 1 つは、必要な学習サンプルセットが比較的少なくすむことです。また、決定木を介して分類の決定につながる情報を追跡することができます。

そしてユーザーは、分類器の判定に必要な“最低限の信頼度”を「つまみ」ひとつで決定できます。確信が持てない欠陥は、更なる改良のために未知のカテゴリに分類されます。

欠陥を分類する方法がすでに完璧に分かっていて、AI を必要としないケースがしばしばあります（図 4 参照）。このような場合、優れた AI 分類システムは、信頼度情報を用いて AI 分類をバイパスまたは補完する手段を提供します。

ニューラルネットワークは、何十年にもわたって機械学習にも使用されてきました。1990 年代後半から 2000 年代前半にかけては、ニューラルネットワークがサンプルの範囲外から外挿する際に予測不能となるため、慎重に選択されたサンプルセットに大きく依存する基本的な問題についてはあまり進展がありませんでした。近年研究が再燃し、2012 年にディープラーニングの論文が発表されるなど、画像ベースの物体認識分野での適性が大幅に改善され、実環境での性能も大幅に向上しています。産業用途の場合、ニューラルネットワークの判断は可視的でないため、学習セットをさらに改良する以外には、それらを改善することは困難です。また、ニューラルネットワークは、C5.0 のアプローチと比較して、より大きな学習セットを必要とするというのが一般的な意見です。

また、物体認識の AI 手法として **サポートベクターマシン (SVM)** がありますが、SVM の学習方法は非常に複雑で、専門家以外のトレーニングの試みには適していません。

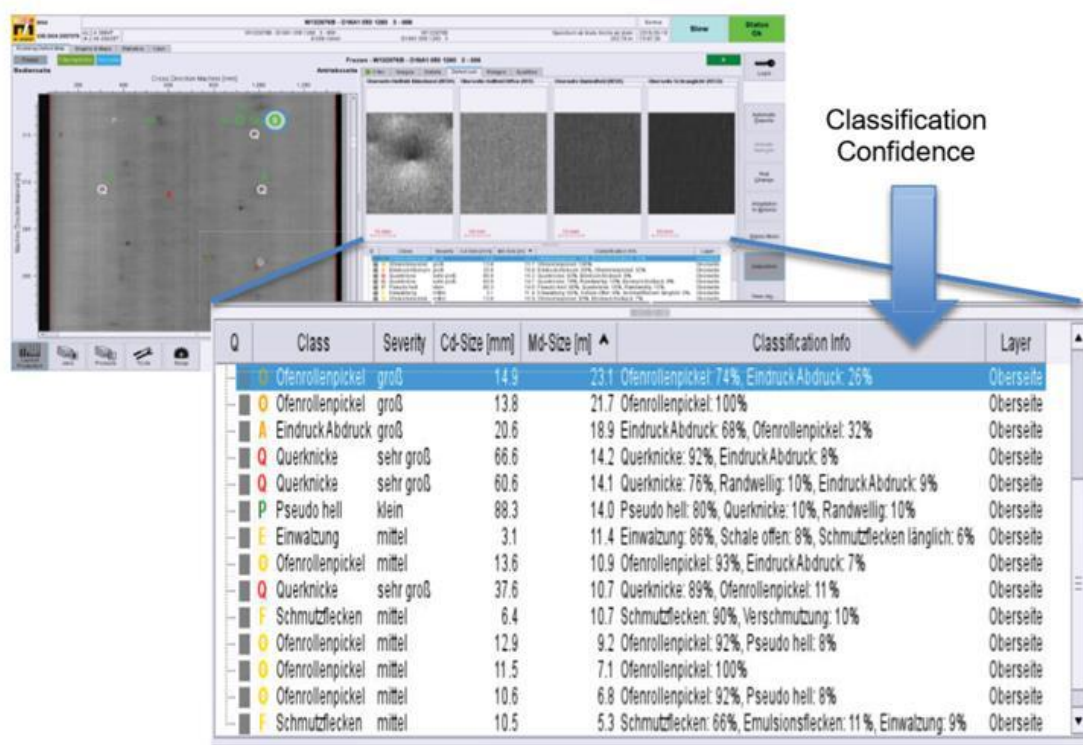


図 4: 信頼度情報を用いたオンザフライ欠陥分類

## 包括的なツールセットの重要性

機械学習のためのサンプルセットを作成する際に重要なのは、一貫した“ラベリング (AI システムにこの欠陥を何と呼ばせたいか)”と“アノテーション (注釈: 欠陥の概要は何か)”の 2 点です。

一貫した欠陥サンプルの収集を容易にするための優れたツールセットは極めて重要です。私たちは、結局のところ、学校の先生が子供に教えるのと同じように、ここで機械に教えているのです。もし、その教えが一貫していなかったり、矛盾していたりすれば、結果も同じように一貫せず、混乱したものになるでしょう。

そこで、ユーザーの欠陥ライブラリ作成を支援することを目的としたワークベンチを設計しました (図 5 参照)。ラベリング部分については、ワークベンチはユーザーがいくつかの欠陥例を分類した後、欠陥がどのカテゴリに属しているかについての提案を提供します。基本的にワークベンチはユーザーに「これはこの欠陥のように見えます」と伝え、提案に対して一定レベルの信頼性を提供します。

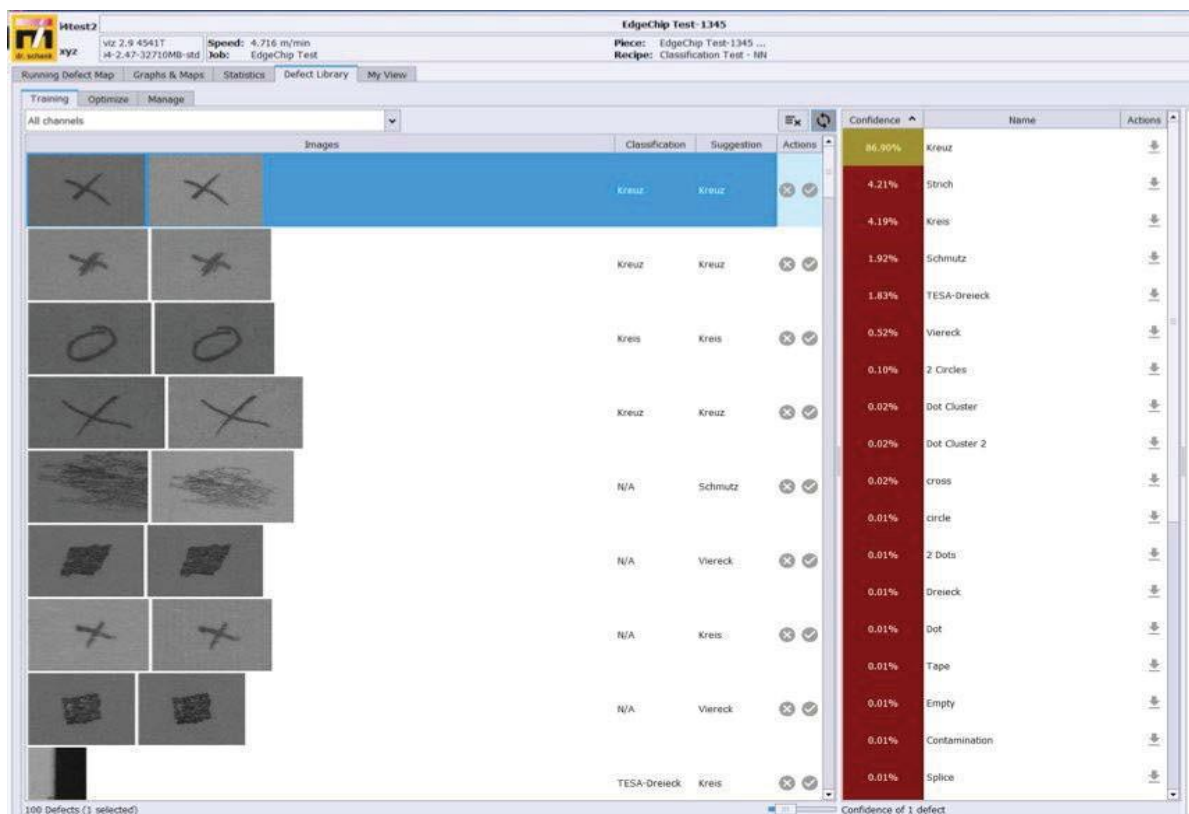


図 5: 欠陥ライブラリ作成ワークベンチ

## 達成された欠陥分類の改善

表1は、単一の(自動学習された)決定木分類器とブースティングを伴う C5.0 アルゴリズムによる改善を示しています。分類器が最終的にどれだけ優れたものになるかは、学習セットの品質、発生した欠陥をどれだけ代表しているか、システムが提供する画像数(光学系チャネル数:単一の画像で類似している欠陥を区別できるように)に大きく依存します。

**表 1: Single Decision-Tree 分類器とブースティングを伴う C5.0 アルゴリズムによる改善**

Library	Classifier Error Rate		Improvement [%]
	Rule-Based [%]	Boosted DT [%]	
Fiber Mat (4 views)	12.30	7.90	35.77
Label (single view)	28.20	23.50	16.66
OCR Experiment (single view, very good training set)	1.20	0.90	25.0
Packaging Film 1 (single view)	29.80	20.00	32.9
Packaging Film 2 (2 views)	8.80	7.70	12.5
Rolled Steel (2 views)	31.30	16.20	48.24
Average Improvement			28.51

## 要約

自動光学検査(AOI)システムのセットアップと最適化において、それぞれのタスクに適した AI(Artificial Intelligence)手法を選択することで、必要な時間と労力が大幅に削減されました。AOIシステムを最大限に活用するために、ユーザーは、ビジョンシステムの操作や設定の専門家をもはや必要としません。ユーザーは、実際の製品品質の定義の評価に集中することができ、システムを品質保証だけでなく、プロセスの問題点の特定とその修正に迅速に利用できるようになりました。AOI によって提供されるより正確なデータは、出荷品質を保証するだけでなく、大幅なプロセス改善と生産量の最適化をもたらします。



**図 6. 稼働中の検査システム**