



PREDICTIVE MAINTENANCE - ANHAND VON SENSORDATEN AUSFÄLLE IM PNEUMATISCHEN SYSTEM VON TRUCKS VORHERSAGEN

PROJEKTZIEL

Das pneumatische System ist ein kritisches Element in jedem Truck. Die erzeugte Druckluft ist entscheidend für die Funktionalität des Bremsen- und Getriebesystems. Ein Defekt kann daher zu erheblichen Schäden, Totalausfällen und somit zu sehr hohen Kosten führen. Um Defekte vorzubeugen ist dementsprechend ein hoher Wartungsaufwand erforderlich.

Eine Vielzahl von Sensoren sind in jedem Truck verbaut, um den aktuellen Zustand vieler Fahrzeugkomponenten zu erfassen. Das Ziel dieses Projektes war es diese Sensordaten mittels eines Machine Learning Modells zu analysieren und vorherzusagen, ob ein Defekt des pneumatischen Systems zu erwarten ist. Geeignete Wartungsmaßnahmen können somit rechtzeitig eingeleitet werden und Kosten durch Defekte und unnötige Wartungen vermieden werden. Kritisch für den Erfolg dieses Projektes war es einerseits eine hohe Vorhersagegenauigkeit für Defekte am pneumatischen System zu realisieren und dabei möglichst wenige Fehlalarme zu generieren. Durch eine erfolgreiche Implementierung können erhebliche Kostenersparnisse erzielt werden.

DATENSATZ

Der zur Verfügung gestellte Datensatz umfasste sowohl einen Trainings- als auch einen Testdatensatz. Letzterer dient dazu die Vorhersagegenauigkeit an ungesehenen Daten zu beurteilen. Zum Trainieren des Modells beinhaltete der Trainingssatz Sensordaten von insgesamt 60.000 Trucks. Davon wurde bei 1.000 Trucks ein Defekt im pneumatischen System erfasst. Zum Validieren der Vorhersagegüte wurden weitere Sensordaten von 16.000 Trucks übermittelt. Die Sensordaten beinhalteten insgesamt 171 Kennzahlen für jeden Truck.

HERAUSFORDERUNGEN

Viele der Sensordaten zeigten Lücken auf und ein Umgang mit diesen Werten musste gefunden werden.

Bei der Evaluierung der Modellpräzision muss eine differenzierte Gewichtung der Fehlvorhersagen vorgenommen werden. Einen tatsächlichen Defekt des pneumatischen Systems nicht vorherzusagen ist weitaus kritischer, als ein Fehlalarm, der lediglich zu unnötigen Wartungskosten führt. Eine entsprechende Priorisierung zur Vermeidung von nichtvorhergesagten Defekten innerhalb des Modells ist daher notwendig.

Das Verhältnis der Daten von defekten pneumatischen Systemen und intakten Systemen ist sehr unausgeglichen (1.000:59.000), was in der Vorhersage zu einer zu großen Fokussierung auf intakte Systeme führt. Da insbesondere die defekten Systeme von zentralem Interesse sind, muss eine entsprechende Ausbalancierung erfolgen.

ANGEWANDTE METHODIK

Um die Verteilung und den Informationsgehalt der Sensordaten nicht zu verzerren, wurden fehlende Werte mit den entsprechenden Mittelwerten ersetzt. Da die Sensordaten sehr unterschiedliche Wertebereiche aufwiesen, wurde eine Normalisierung der Werte auf das Intervall -1 und $+1$ durchgeführt. Dies diente der Performance des Modells. Das Problem der unausgeglichene Verteilung von Defekten zu Nicht-Defekten wurde durch ein Bootstrapping-Verfahren und eine entsprechenden Klassengewichtung innerhalb des Modells angegangen. Dadurch wurde der Priorisierung auf hohe Präzision bei der Vorhersage von Defekten Rechnung getragen.

In einem Modellauswahlprozess wurden verschiedene Algorithmen bezüglich ihrer Vorhersagekraft beurteilt. Die Modelle wurden dabei an die Daten angepasst und deren Parameter entsprechend optimiert mittels eines grid search Verfahrens. Unter den untersuchten Modellen waren die Logistische Regression, Random Forest Classifier, Support Vector Classifier, Quadratic Discriminant Analysis (QDA) und Neuronale Netze.

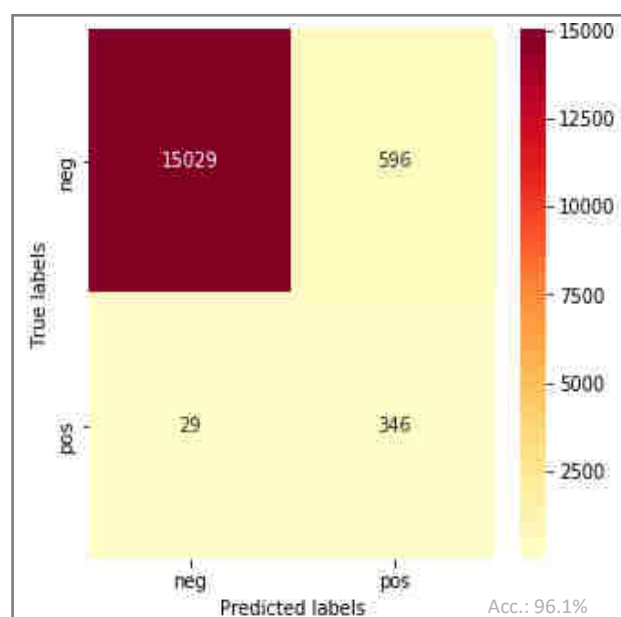

Der Support Vector Classifier erzielte dabei mit 98,9% die höchste allgemeine Genauigkeit. Obwohl es die wenigsten falschen Vorhersagen lieferte, wurde eine große Menge an Defekten nicht erkannt. Da dies das Kernkriterium des Projektes war, wäre eine praktische Anwendung nicht zielführend. Die QDA hingegen verpasste deutlich weniger Defekte in der Vorhersage und ist daher trotz seiner etwas niedrigeren Gesamtvorhersagekraft von 96,1% klar zu bevorzugen. Durch die QDA konnten 92,3% der Defekte vorhergesagt werden und es wurde nur in 3,8% der Fälle ein Falschalarm ausgelöst.

PROJEKTERGEBNIS

Das trainierte Machine Learning Modell erzielte mit 92,3% eine hohe Genauigkeit bei der Vorhersage von Defekten des pneumatischen Systems und hatte dabei eine niedrige Fehlalarmrate von nur 3,8%. Die vorgeschlagene Methodik kann in der Praxis als Unterstützung bei der Defektprävention eingesetzt werden und ermöglicht gezieltere Wartungsmaßnahmen.

WEITERE ANWENDUNGSGEBIETE

Die vorgestellte Methodik kann in ein Prozesskontroll-Framework überführt werden, welches in Echtzeit automatisiert Unregelmäßigkeiten in Sensordaten aufdecken kann. Dadurch können entsprechend Warnungen und angemessene Maßnahmen ergriffen werden. Da der zur Verfügung gestellte Datensatz recht klein war, kann die Präzision des vorgestellten Modells, durch den Einsatz von mehr Daten oder weiterer Sensoren zu potentiellen Einflussfaktoren auf das pneumatische System, weiter gesteigert werden. Eine angepasste Version des Modells kann ebenso für Vorhersagen zu Defekten anderer Fahrzeugkomponenten eingesetzt werden.



Vorhersagegüte für den Support Vector Klassifizierer (links) und die Quadratic Discriminant Analysis (rechts)

