Q in KI: Anforderungen an Tools und Prozesse zur Absicherung

Anleitung zur Nutzung von AssessML

Dr. Björn Schünemann (bjoern.schuenemann@aqigmbh.de)
Dr. Jürgen Großmann (juergen.grossmann@fokus.fraunhofer.de)

Vorgehen im Projekt und verwendete Terminologie

Vom KI-Entwicklungszyklus zur Werkzeugqualifizierung

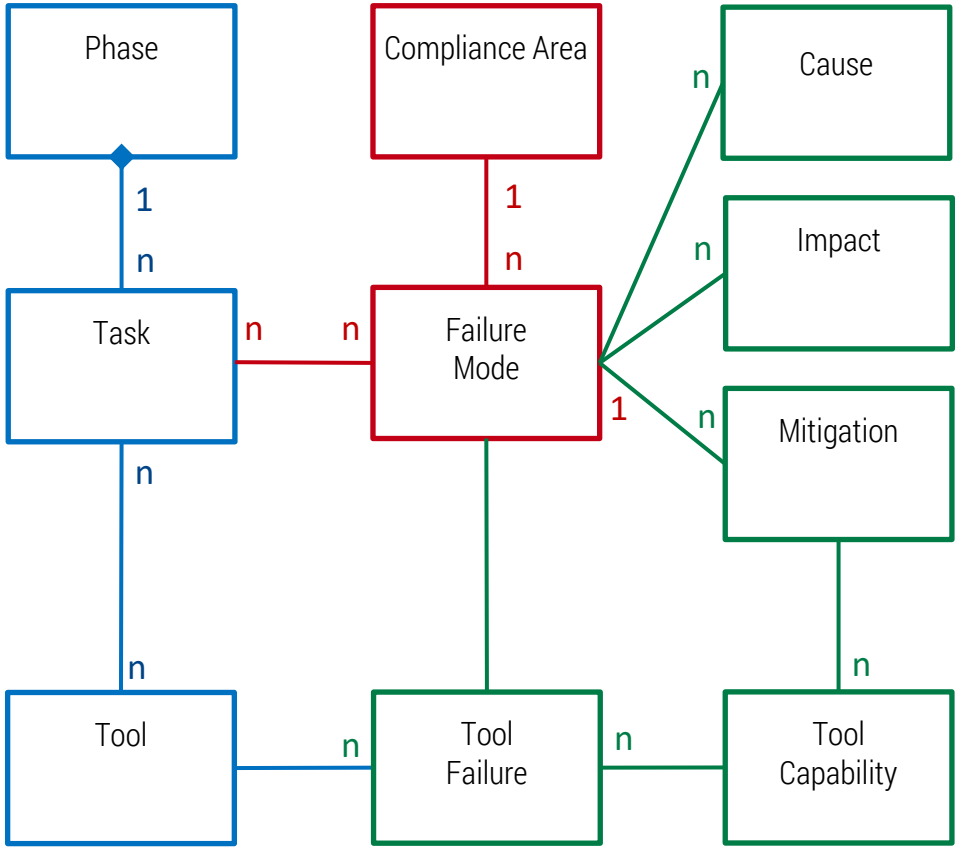

- Systematische Aufstellung der **Phasen (Phase)** und **Aufgaben (Task)** im KI-Entwicklungszyklus sowie beispielhafter **Werkzeuge (Tool).**
- Identifikation der **Abweichungen / Fehlerzustände (Failure Mode)** entlang der **Aufgaben** für jedes **Konformitätsgebiet (Compliance Area).**
- Identifikation von **Ursachen (Cause), Wirkungen (Impact)** und möglicher **Gegenmaßnahmen (Mitigation)** für jede **Abweichung (Failure Mode).**
- Identifikation von spezifischen **nicht-konformem Verhalten von Werkzeugen (Tool Failure)** und benötigter **Werkzeugfähigkeiten (ToolCapability)** für eine **Abweichung (Failure Mode).**

Phase (Phase): Phase aus dem KI-Entwicklungszyklus

Task (Aufgabe): Aufgabe während des KI-Entwicklungszyklus, die von Werkzeugen unterstützt wird.

Tool (Werkzeug): Werkzeug, dass eine Aufgabe unterstützt/ausführt.

Compliance Area (Konformitätsgebiet): Konformitätsgebiet (funktionale Sicherheit, Datenschutz, KI-Regulierung).

Failure Mode (Fehlerzustand): Abweichung, die zu Nichtkonformität führt.

Tool Failure (Werkzeugfehler): Nicht-konformes Verhalten von Werkzeugen als Ursache für eine Abweichung

Cause (Ursache): Ursachen für das Zustandekommen der Abweichung.

Impact (Auswirkung): Auswirkungen, die die Abweichung hat.

Mitigation (Minderung): Maßnahme zur Vermeidung der Abweichung.

Tool Capability (Werkzeugfähigkeiten): Benötigte Fähigkeiten eines Werkzeugs zur Vermeidung der Abweichung.

Systematische Ausarbeitung der Inhalte

Ergebnis ist eine Python-basierte Webanwendung

Terminologie

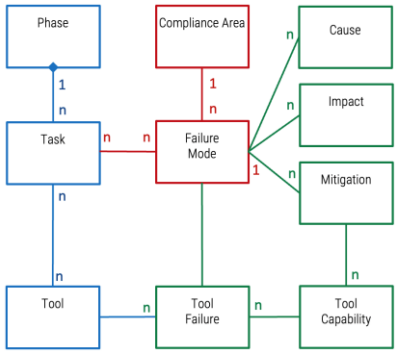

Inhalte der Excel-Tabelle werden gemäß verwendeter Terminologie erarbeitet

Compliance Area	Phase	Task	Failure Mode	Impact	Severity	Causes	Mitigation	Occurrence	Detectability	RPN	Potential Tool Failure	Recommended Tool Capability
Functional Safety	Training & Validation	Deep Learning & ML Frameworks	Lack of Real-Time Processing	Trained models and supporting frameworks are unable to deliver low-latency, real-time inference performance required for critical applications such as autonomous systems.		Model architectures are too large or complex for target real-time environments. Frameworks do not leverage hardware acceleration efficiently (e.g., GPU, TPU, Edge devices). Pipeline overhead (e.g., preprocessing, postprocessing) adds excessive latency during inference.	Apply model optimization techniques such as pruning, quantization, or knowledge distillation. Ensure deployment-ready models are benchmarked and optimized for specific hardware accelerators. Optimize full pipeline latency by batching operations and reducing unnecessary transformations.				May fail to guarantee deterministic training execution and runtime validation, resulting in trained models that do not meet real-time safety-critical performance requirements.	Framework support for model optimization (e.g., TensorRT, ONNX Runtime optimizations). Support for hardware-specific runtime optimizations and deployment targeting (e.g., EdgeTPU, CUDA kernels). Framework support for pipeline fusion, minimal preprocessing APIs, and asynchronous inference.
Functional Safety	Training & Validation	Deep Learning & ML Frameworks	Inadequate Error Handling & Logging	Frameworks and models lack robust error detection, recovery, and structured logging capabilities, making root cause analysis and system recovery difficult.		Training and inference exceptions are not properly caught or logged. Losses, gradients, or other training dynamics are not systematically monitored for anomalies. Training and deployment pipelines lack comprehensive logging and metadata tracking.	Integrate structured exception handling and mandatory logging for all critical training and inference operations. Implement runtime monitors for numerical instabilities (e.g., NaNs, divergence) and alert on thresholds. Embed pipeline-wide metadata capture and systematic experiment logging into the training framework.				May fail to provide comprehensive error logging and runtime monitoring, resulting in trained models with limited traceability for failure analysis in safety-critical systems.	Framework support for structured error reporting, custom callbacks, and logging integration. Built-in hooks for anomaly detection during training and validation (gradient checkers, divergence detectors). ML lifecycle management tools (e.g., MLflow, Weights & Biases) integration for metadata and error tracking.
Functional Safety	Training & Validation	Deep Learning & ML Frameworks	Model Instability & Poor Generalization	Inconsistent training leading to unreliable AI behaviour in critical applications.		Lack of deterministic/reproducible training settings due to parallel computation and floating-point arithmetic. Limited built-in validation or monitoring. No built-in numerical stability mechanisms.	Implement deterministic training pipelines with seed control and precision configuration to ensure repeatability. Integrate continuous performance monitoring during training with automatic validation checkpoints. Use frameworks that incorporate gradient clipping, normalization, and regularization for improved numerical robustness.				May fail to enforce deterministic training procedures and runtime validation, resulting in trained models with unpredictable behavior and poor generalization in safety-critical applications.	Explicit deterministic training support with reproducibility settings and controlled parallelism. Built-in validation dashboards and metric tracking APIs. Numerical stability modules with configurable regularization options.

Dashboard wurde basierend auf der Excel-Tabelle erstellt

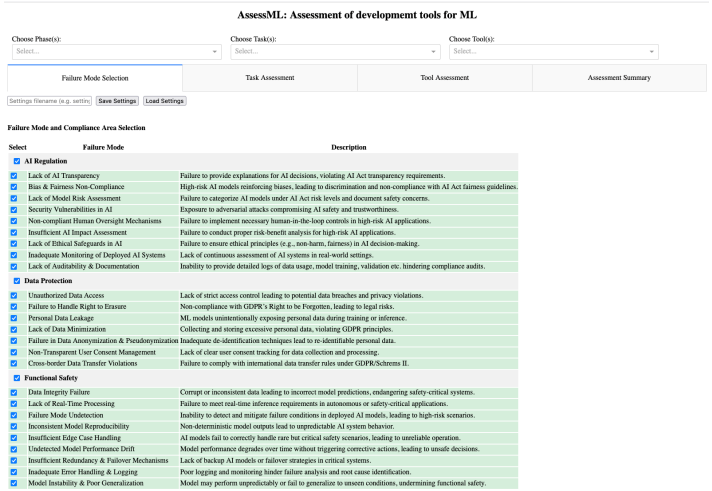

Risikobasierte Werkzeugqualifizierung (Details)

Zweistufiges Verfahren zur Ermittlung von aufgabenbezogenen Risiken und einer Qualifizierung von Werkzeugen entlang der Risiken

AQI | Automotive Quality Institute

1. Ermittlung von Risiken in den Entwicklungsaufgaben (nach FMEA)

RPN = Severity * Occurrence * Detection

1.1 Auswahl der relevanten Aufgaben und Phasen	1.2 Auswahl der relevanten Konformitätsbereiche und Fehlermodi	1.3. Berechnung des RPN für ausgesuchte Fehlermodi in einer Aufgabe

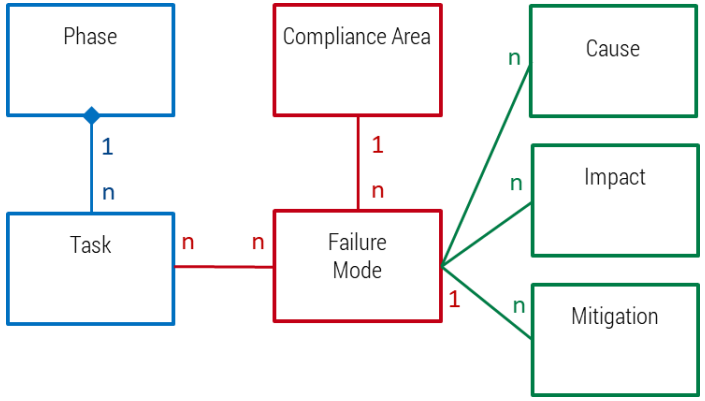

2. Ermittlung des Qualifizierungsbedarfs für KI-Werkzeuge

2.1 Einschätzung über die Bedeutung des Werkzeugs für eine Abweichung (Tool Impact)	2.2 Bewertung der Erkennbarkeit des Werkzeugfehlers (Tool Error Detection) und Bestimmung des Tool Confidence Level (TCL) pro Konformitätsbereich	2.3 Abschließende Werkzeugbewertung und Handlungsempfehlung auf Basis der RPN und des TCL

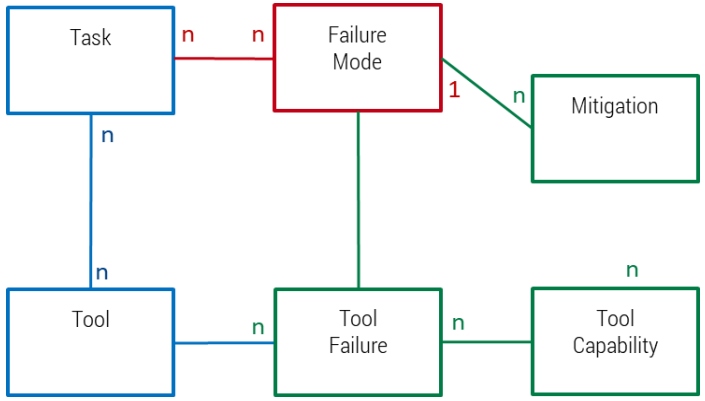

AssessML: Aufbau des Dashboardes

Automotive Quality Institute

Startseite

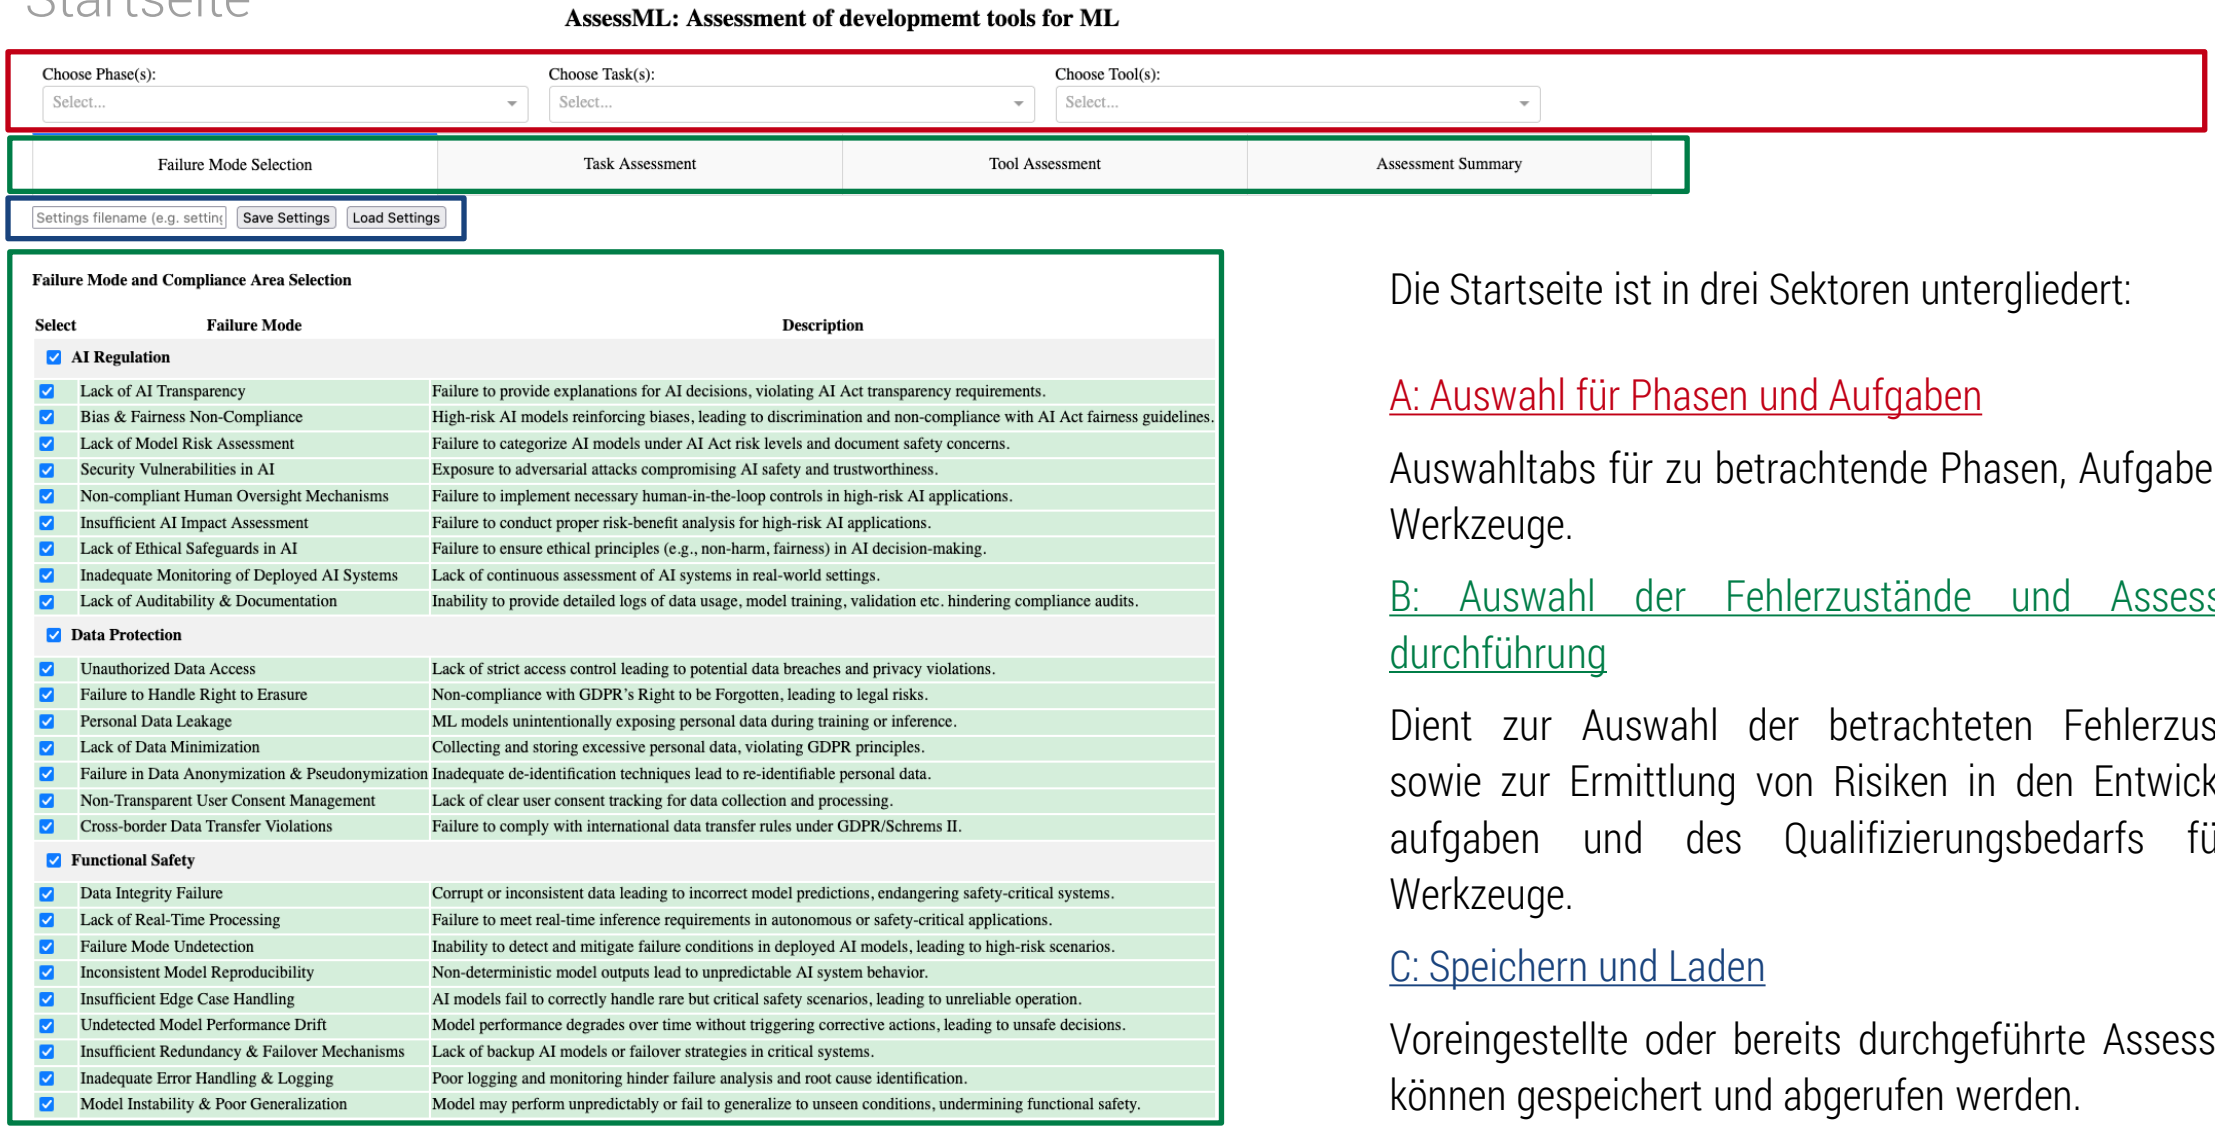

Select	Failure Mode	Description
☑	**AI Regulation**	
☑	Lack of AI Transparency	Failure to provide explanations for AI decisions, violating AI Act transparency requirements.
☑	Bias & Fairness Non-Compliance	High-risk AI models reinforcing biases, leading to discrimination and non-compliance with AI Act fairness guidelines.
☑	Lack of Model Risk Assessment	Failure to categorize AI models under AI Act risk levels and document safety concerns.
☑	Security Vulnerabilities in AI	Exposure to adversarial attacks compromising AI safety and trustworthiness.
☑	Non-compliant Human Oversight Mechanisms	Failure to implement necessary human-in-the-loop controls in high-risk AI applications.
☑	Insufficient AI Impact Assessment	Failure to conduct proper risk-benefit analysis for high-risk AI applications.
☑	Lack of Ethical Safeguards in AI	Failure to ensure ethical principles (e.g., non-harm, fairness) in AI decision-making.
☑	Inadequate Monitoring of Deployed AI Systems	Lack of continuous assessment of AI systems in real-world settings.
☑	Lack of Auditability & Documentation	Inability to provide detailed logs of data usage, model training, validation etc. hindering compliance audits.
☑	**Data Protection**	
☑	Unauthorized Data Access	Lack of strict access control leading to potential data breaches and privacy violations.
☑	Failure to Handle Right to Erasure	Non-compliance with GDPR's Right to be Forgotten, leading to legal risks.
☑	Personal Data Leakage	ML models unintentionally exposing personal data during training or inference.
☑	Lack of Data Minimization	Collecting and storing excessive personal data, violating GDPR principles.
☑	Failure in Data Anonymization & Pseudonymization	Inadequate de-identification techniques lead to re-identifiable personal data.
☑	Non-Transparent User Consent Management	Lack of clear user consent tracking for data collection and processing.
☑	Cross-border Data Transfer Violations	Failure to comply with international data transfer rules under GDPR/Schrems II.
☑	**Functional Safety**	
☑	Data Integrity Failure	Corrupt or inconsistent data leading to incorrect model predictions, endangering safety-critical systems.
☑	Lack of Real-Time Processing	Failure to meet real-time inference requirements in autonomous or safety-critical applications.
☑	Failure Mode Undetection	Inability to detect and mitigate failure conditions in deployed AI models, leading to high-risk scenarios.
☑	Inconsistent Model Reproducibility	Non-deterministic model outputs lead to unpredictable AI system behavior.
☑	Insufficient Edge Case Handling	AI models fail to correctly handle rare but critical safety scenarios, leading to unreliable operation.
☑	Undetected Model Performance Drift	Model performance degrades over time without triggering corrective actions, leading to unsafe decisions.
☑	Insufficient Redundancy & Failover Mechanisms	Lack of backup AI models or failover strategies in critical systems.
☑	Inadequate Error Handling & Logging	Poor logging and monitoring hinder failure analysis and root cause identification.
☑	Model Instability & Poor Generalization	Model may perform unpredictably or fail to generalize to unseen conditions, undermining functional safety.

Die Startseite ist in drei Sektoren untergliedert:

A: Auswahl für Phasen und Aufgaben

Auswahltabs für zu betrachtende Phasen, Aufgaben oder Werkzeuge.

B: Auswahl der Fehlerzustände und Assessment-durchführung

Dient zur Auswahl der betrachteten Fehlerzustände, sowie zur Ermittlung von Risiken in den Entwicklungs-aufgaben und des Qualifizierungsbedarfs für KI-Werkzeuge.

C: Speichern und Laden

Voreingestellte oder bereits durchgeführte Assessments können gespeichert und abgerufen werden.

1. Ermittlung von Risiken in den Entwicklungsaufgaben

1.1 Auswahl der relevanten Aufgaben und Phasen

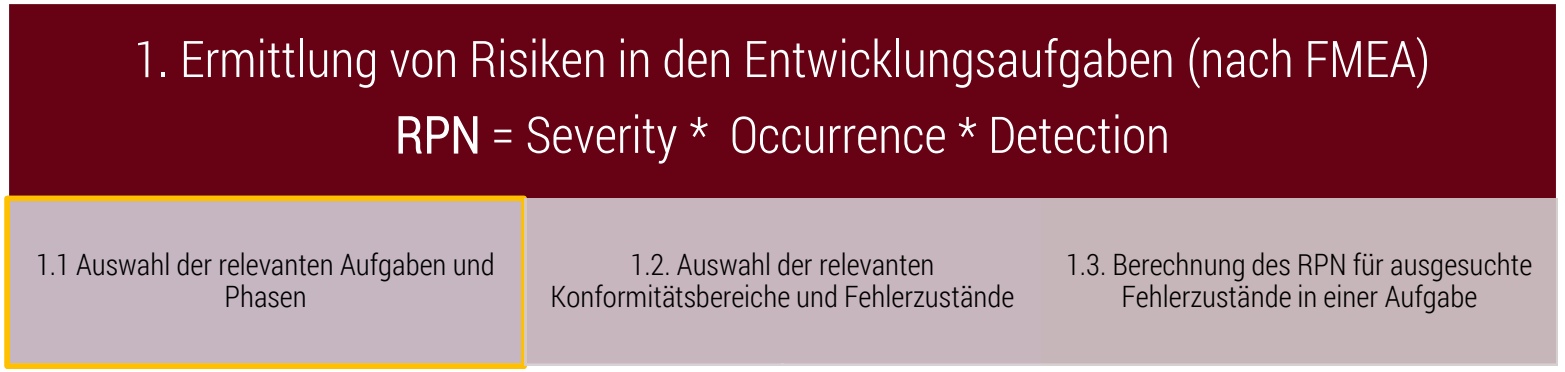

AssessML: Auswahlbereich

Wozu dient der Auswahlbereich?

Das Dashboard beinhaltet 25 Fehlerzustände, die von Start an ausgewählt sind.

Dadurch werden sämtliche Zustände automatisch in das Task und Tool Assessment sowie in die Assessment Summary übernommen, wodurch das Board schnell unübersichtlich werden kann.

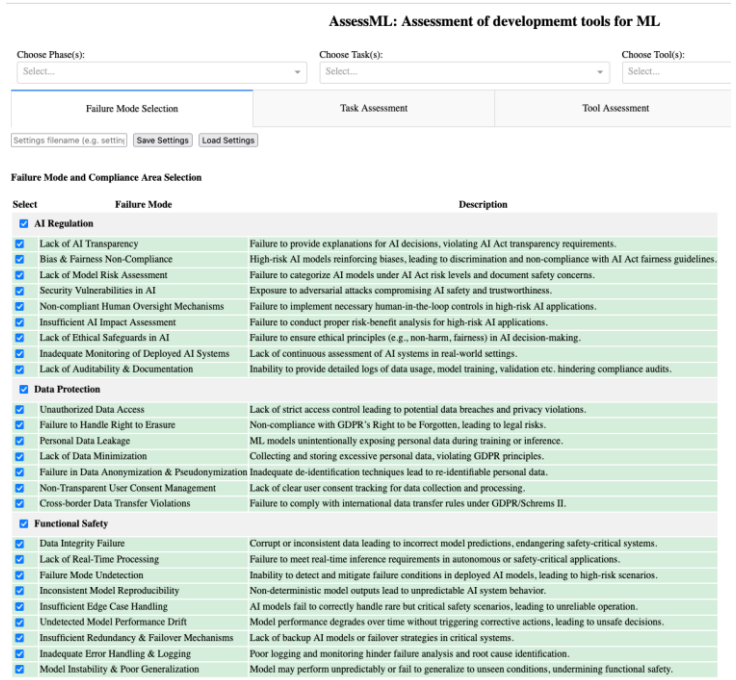

AssessML: Assessment of developmemt tools for ML

Choose Phase(s): Select... | Choose Task(s): Select... | Choose Tool(s): Select...

Failure Mode Selection | Task Assessment | Tool Assessment

Settings filename (e.g. settin) | Save Settings | Load Settings

Failure Mode and Compliance Area Selection

Select	Failure Mode	Description
☑	**AI Regulation**	
☑	Lack of AI Transparency	Failure to provide explanations for AI decisions, violating AI Act transparency requirements.
☑	Bias & Fairness Non-Compliance	High-risk AI models reinforcing biases, leading to discrimination and non-compliance with AI Act fairness guidelines.
☑	Lack of Model Risk Assessment	Failure to categorize AI models under AI Act risk levels and document safety concerns.
☑	Security Vulnerabilities in AI	Exposure to adversarial attacks compromising AI safety and trustworthiness.
☑	Non-compliant Human Oversight Mechanisms	Failure to implement necessary human-in-the-loop controls in high-risk AI applications.
☑	Insufficient AI Impact Assessment	Failure to conduct proper risk-benefit analysis for high-risk AI applications.
☑	Lack of Ethical Safeguards in AI	Failure to ensure ethical principles (e.g., non-harm, fairness) in AI decision-making.
☑	Inadequate Monitoring of Deployed AI Systems	Lack of continuous assessment of AI systems in real-world settings.
☑	Lack of Auditability & Documentation	Inability to provide detailed logs of data usage, model training, validation etc. hindering compliance audits.
☑	**Data Protection**	
☑	Unauthorized Data Access	Lack of strict access control leading to potential data breaches and privacy violations.
☑	Failure to Handle Right to Erasure	Non-compliance with GDPR's Right to be Forgotten, leading to legal risks.
☑	Personal Data Leakage	ML models unintentionally exposing personal data during training or inference.
☑	Lack of Data Minimization	Collecting and storing excessive personal data, violating GDPR principles.
☑	Failure in Data Anonymization & Pseudonymization	Inadequate de-identification techniques lead to re-identifiable personal data.
☑	Non-Transparent User Consent Management	Lack of clear user consent tracking for data collection and processing.
☑	Cross-border Data Transfer Violations	Failure to comply with international data transfer rules under GDPR/Schrems II.
☑	**Functional Safety**	
☑	Data Integrity Failure	Corrupt or inconsistent data leading to incorrect model predictions, endangering safety-critical systems.
☑	Lack of Real-Time Processing	Failure to meet real-time inference requirements in autonomous or safety-critical applications.
☑	Failure Mode Undetection	Inability to detect and mitigate failure conditions in deployed AI models, leading to high-risk scenarios.
☑	Inconsistent Model Reproducibility	Non-deterministic model outputs lead to unpredictable AI system behavior.
☑	Insufficient Edge Case Handling	AI models fail to correctly handle rare but critical safety scenarios, leading to unreliable operation.
☑	Undetected Model Performance Drift	Model performance degrades over time without triggering corrective actions, leading to unsafe decisions.
☑	Insufficient Redundancy & Failover Mechanisms	Lack of backup AI models or failover strategies in critical systems.
☑	Inadequate Error Handling & Logging	Poor logging and monitoring hinder failure analysis and root cause identification.
☑	Model Instability & Poor Generalization	Model may perform unpredictably or fail to generalize to unseen conditions, undermining functional safety.

Task Assessment

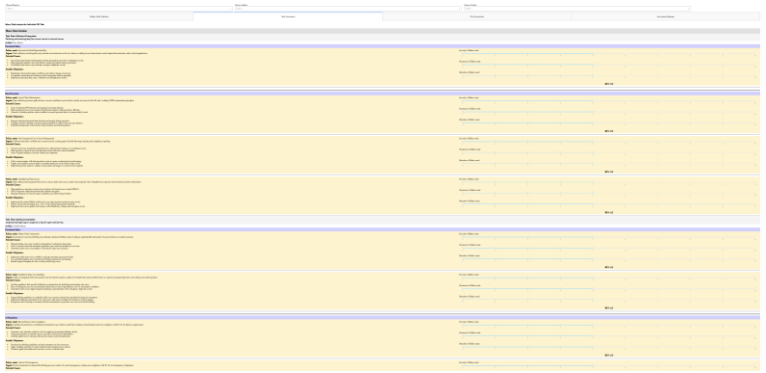

Tool Assessment

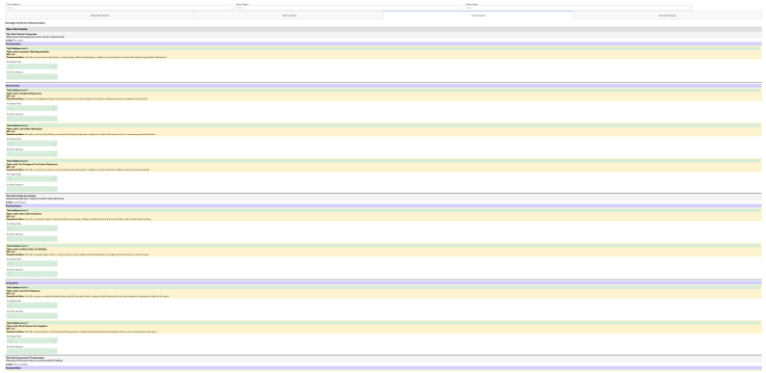

Assessment Summery

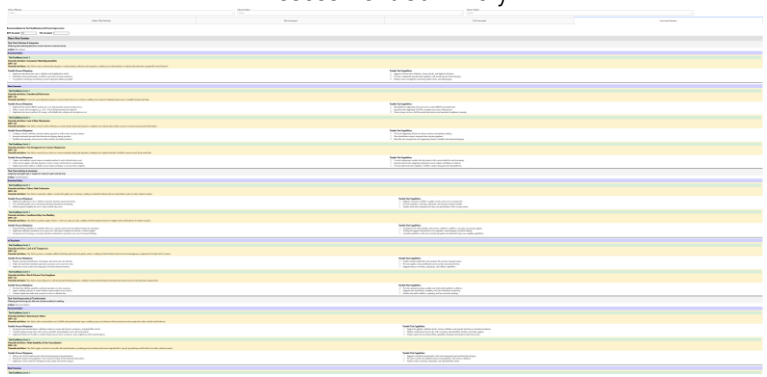

AssessML: Auswahlbereich

Wozu dient der Auswahlbereich?

Um eine gezieltere und effizientere Bearbeitung zu ermöglichen, bietet das Dashboard die Möglichkeit, über den **Auswahlbereich** zu filtern.

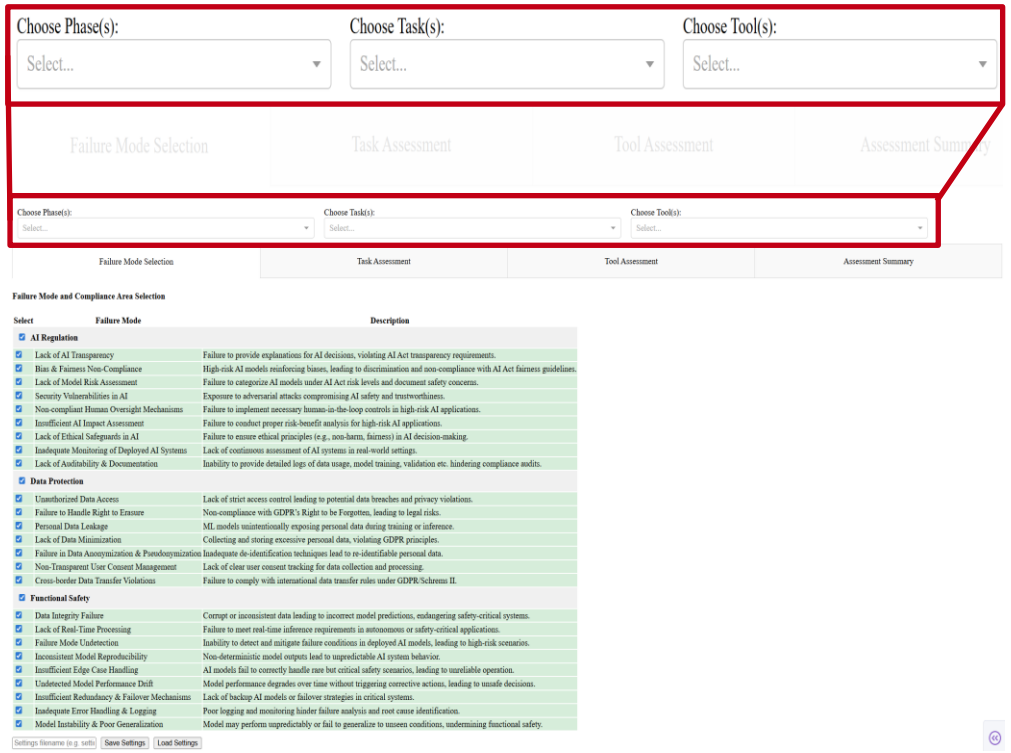

Jede getroffene Auswahl reduziert die angezeigten Fehlerzustände und erleichtert damit die Bearbeitung der folgenden Schritte in den Assessments und in dem Assessments Summary.

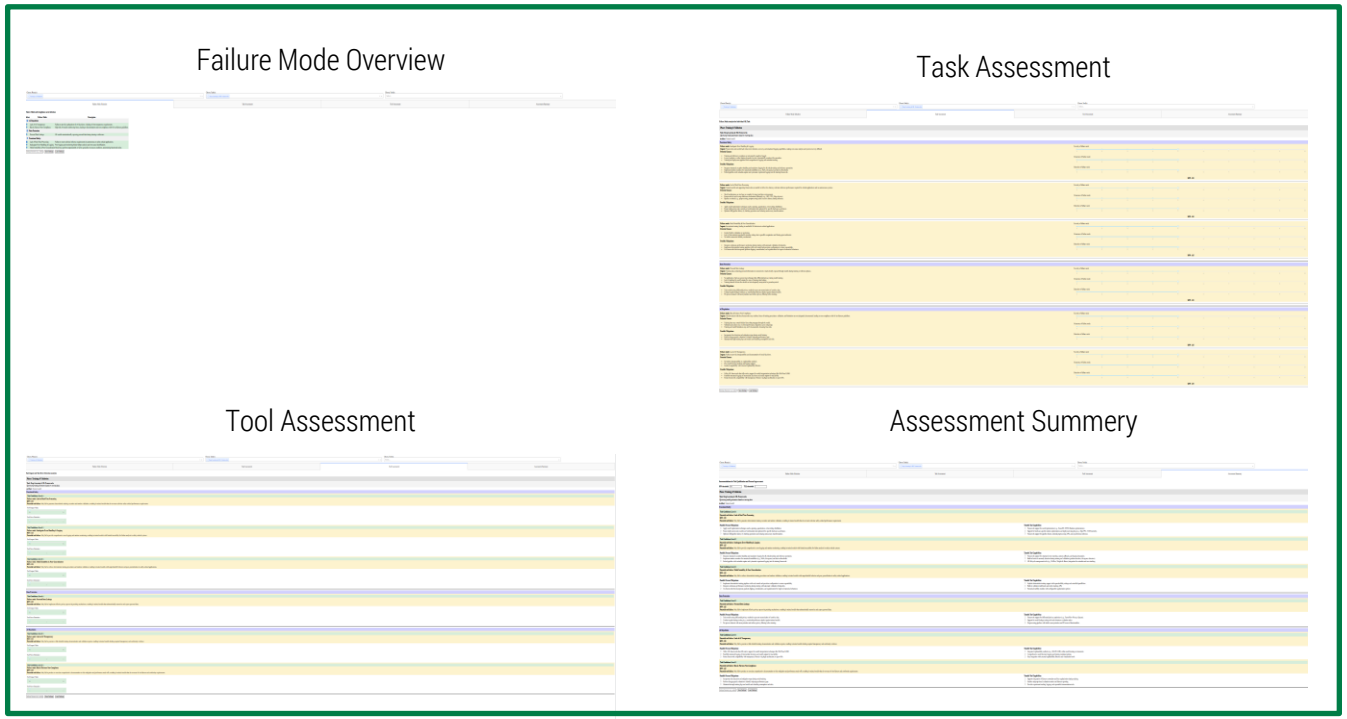

Anleitung für Assessments folgt ab Folie 18

AssessML: Auswahlbereich

1. Auswahlbereich

Der Auswahlbereich unterteilt sich in die drei **Suchtabs** *Phase, Aufgabe und Werkzeuge*, wodurch dem Nutzer ermöglicht wird, die Untersuchung auf die präferierten Phasen und Aufgaben zu beschränken. Dabei gibt es **zwei** Arten Phase und Aufgabe zu bestimmen:

1. Weg: Phasen und Aufgaben

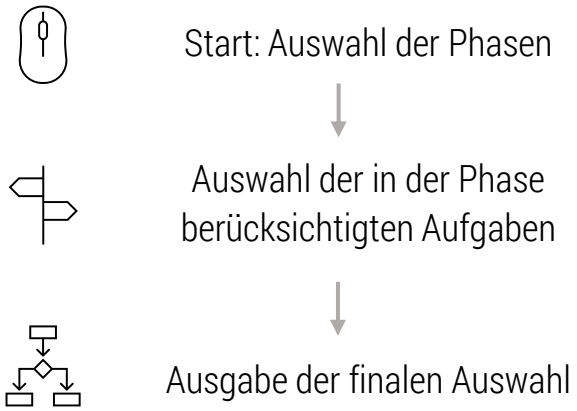

2. Weg: Werkzeuge

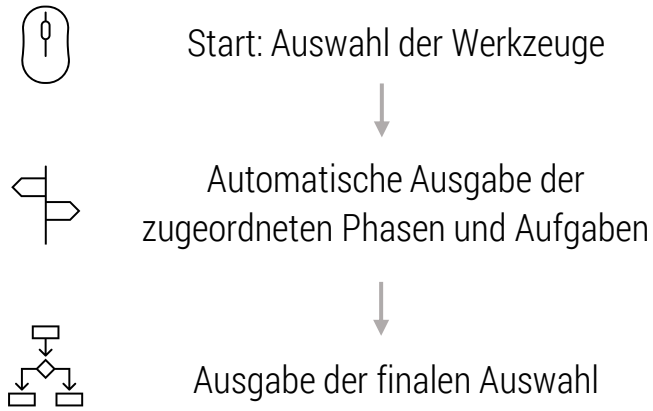

AssessML: Auswahlbereich

1. Weg: Phasen und Aufgaben

Automotive Quality Institute

Start: Auswahl der betrachteten Phasen

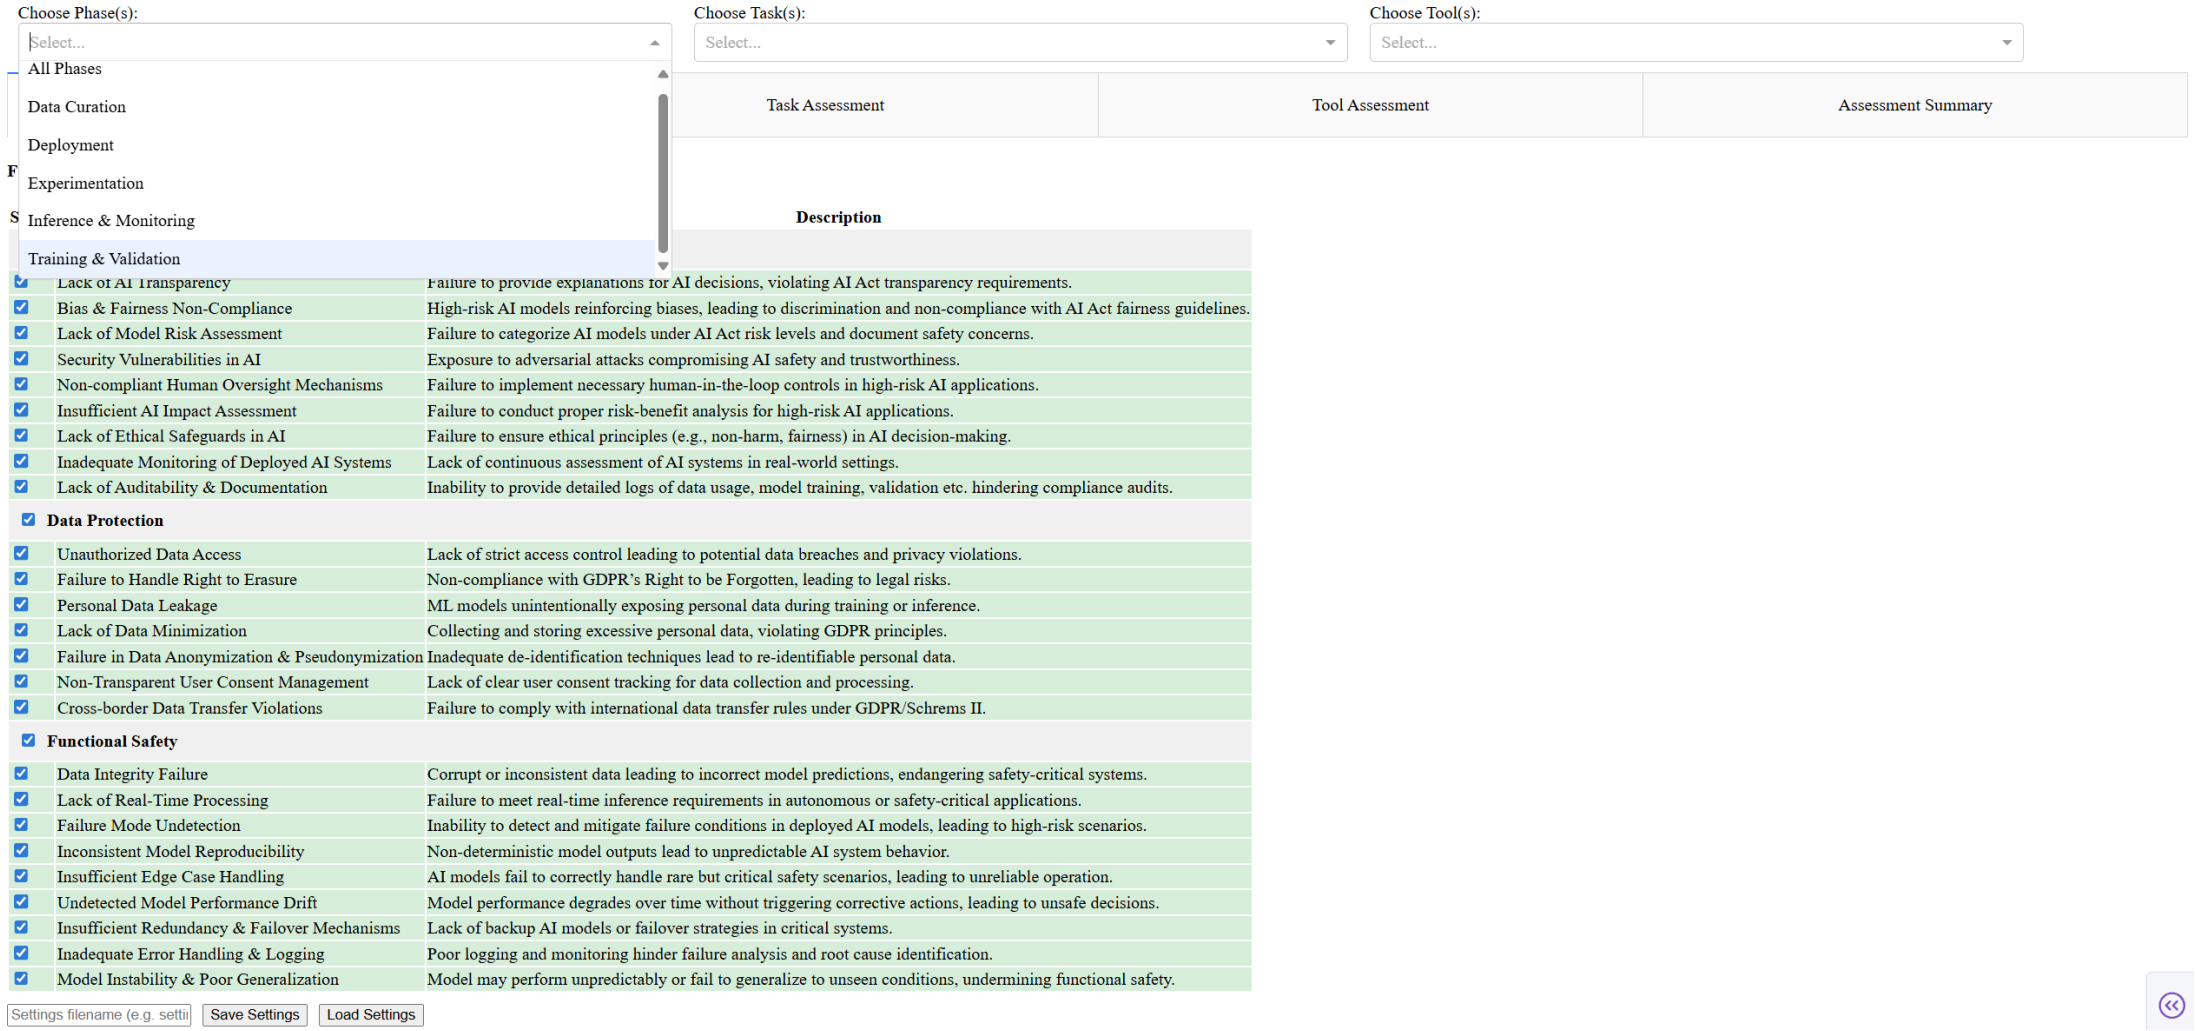

AssessML: Auswahlbereich

1. Weg: Phasen und Aufgaben

Auswahl der in der Phase berücksichtigten Aufgaben

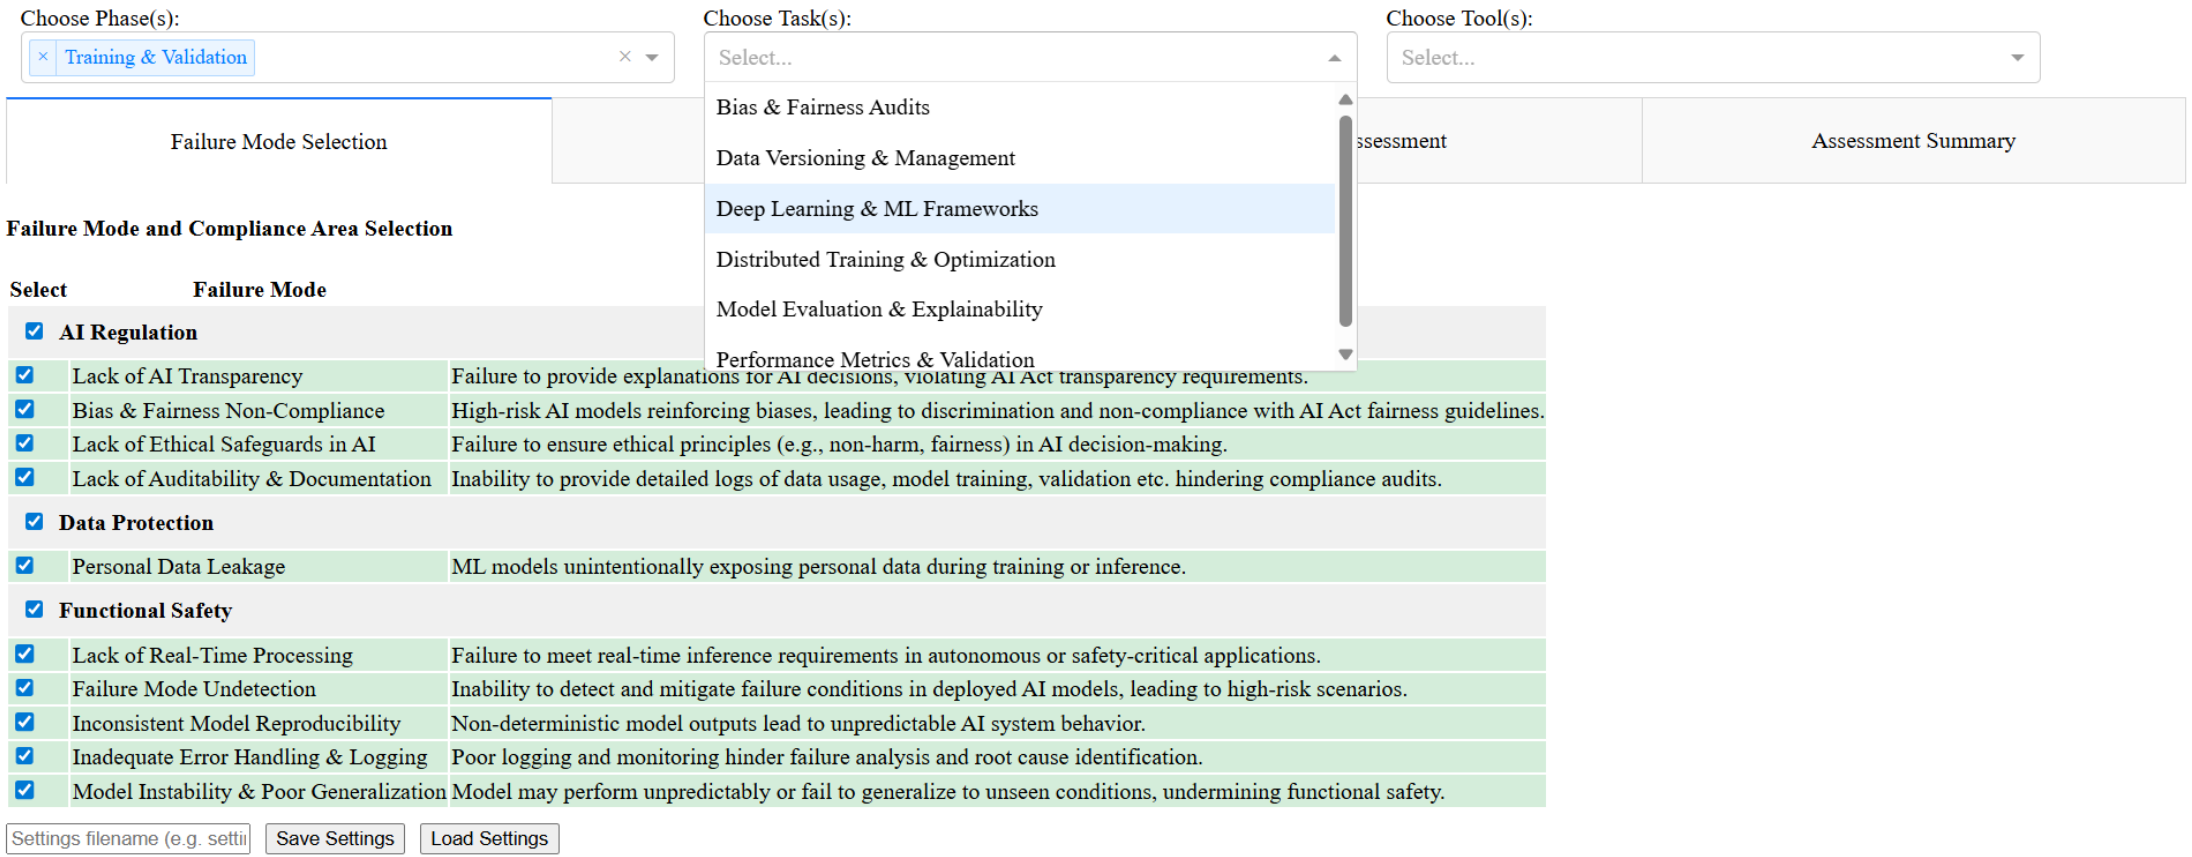

Hinweis:

Durch Auswahl der Phasen erfolgt eine automatische Filterung der Fehlerzustände.

AssessML: Auswahlbereich

1. Weg: Phasen und Aufgaben

Automotive Quality Institute

Ausgabe der finalen Auswahl

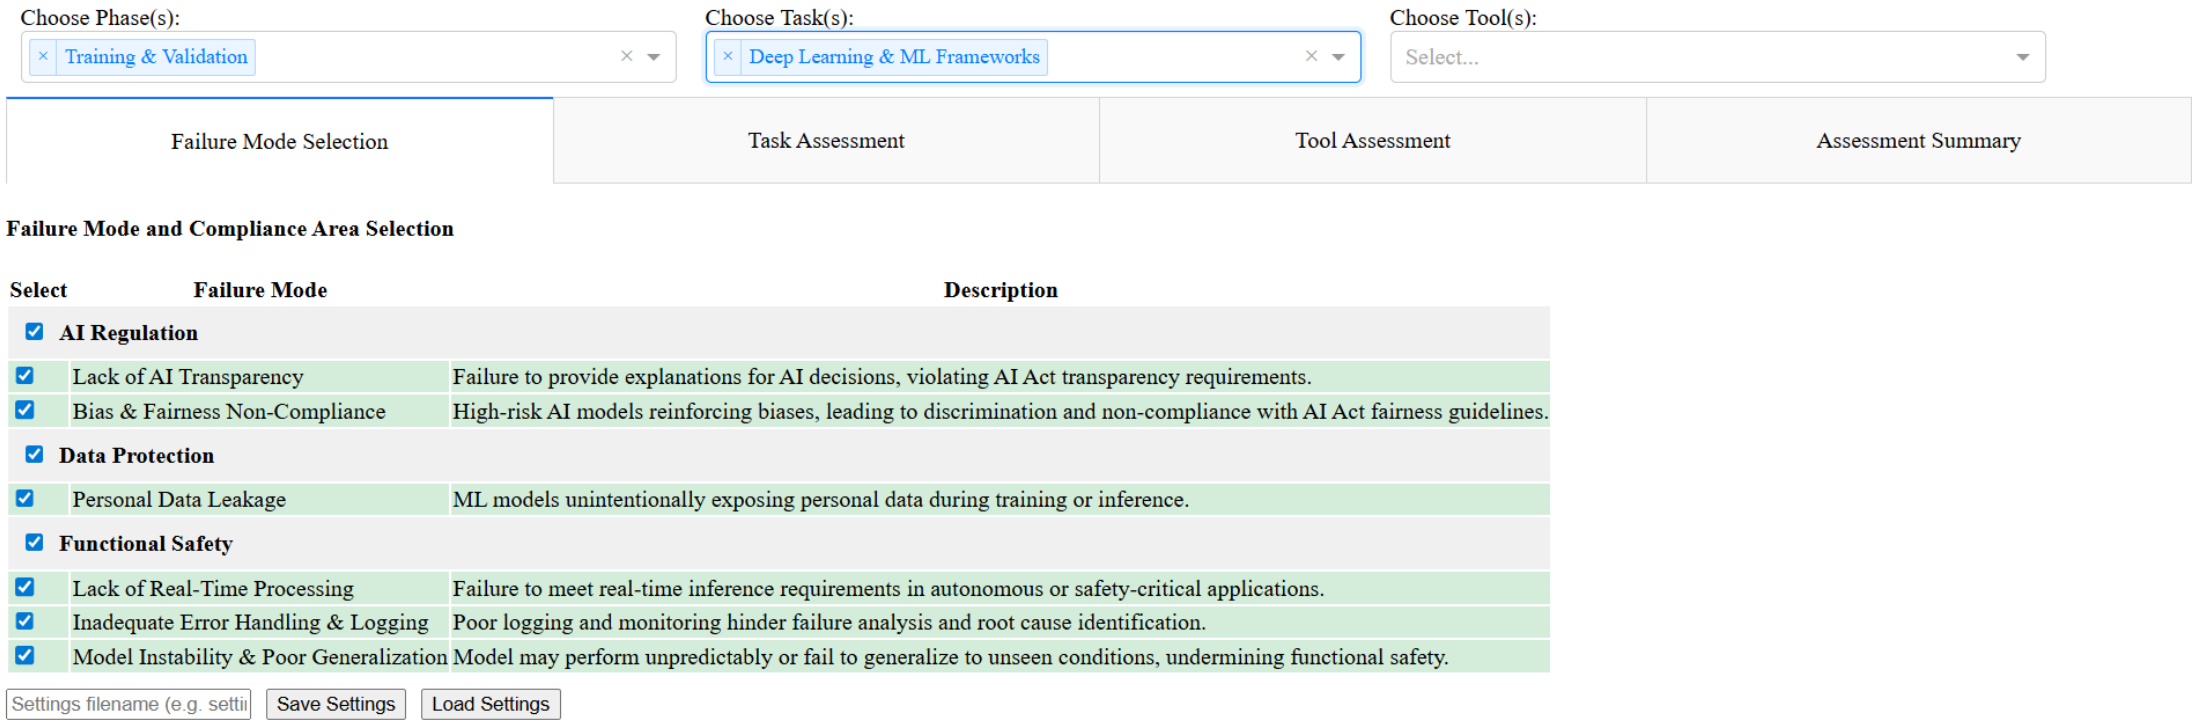

Nachdem die Tabs „Phasen“ und „Aufgaben“ von links nach rechts durchgegangen sind, zeigt das Dashboard alle potenziellen Fehlerzustände an, die durch die Filterung übrig geblieben sind. → Es erfolgt eine Einschränkung der möglichen Fehlerzustände!

AssessML: Auswahlbereich

2. Weg: Werkzeuge

Start: Auswahl der verwendeten Werkzeuge

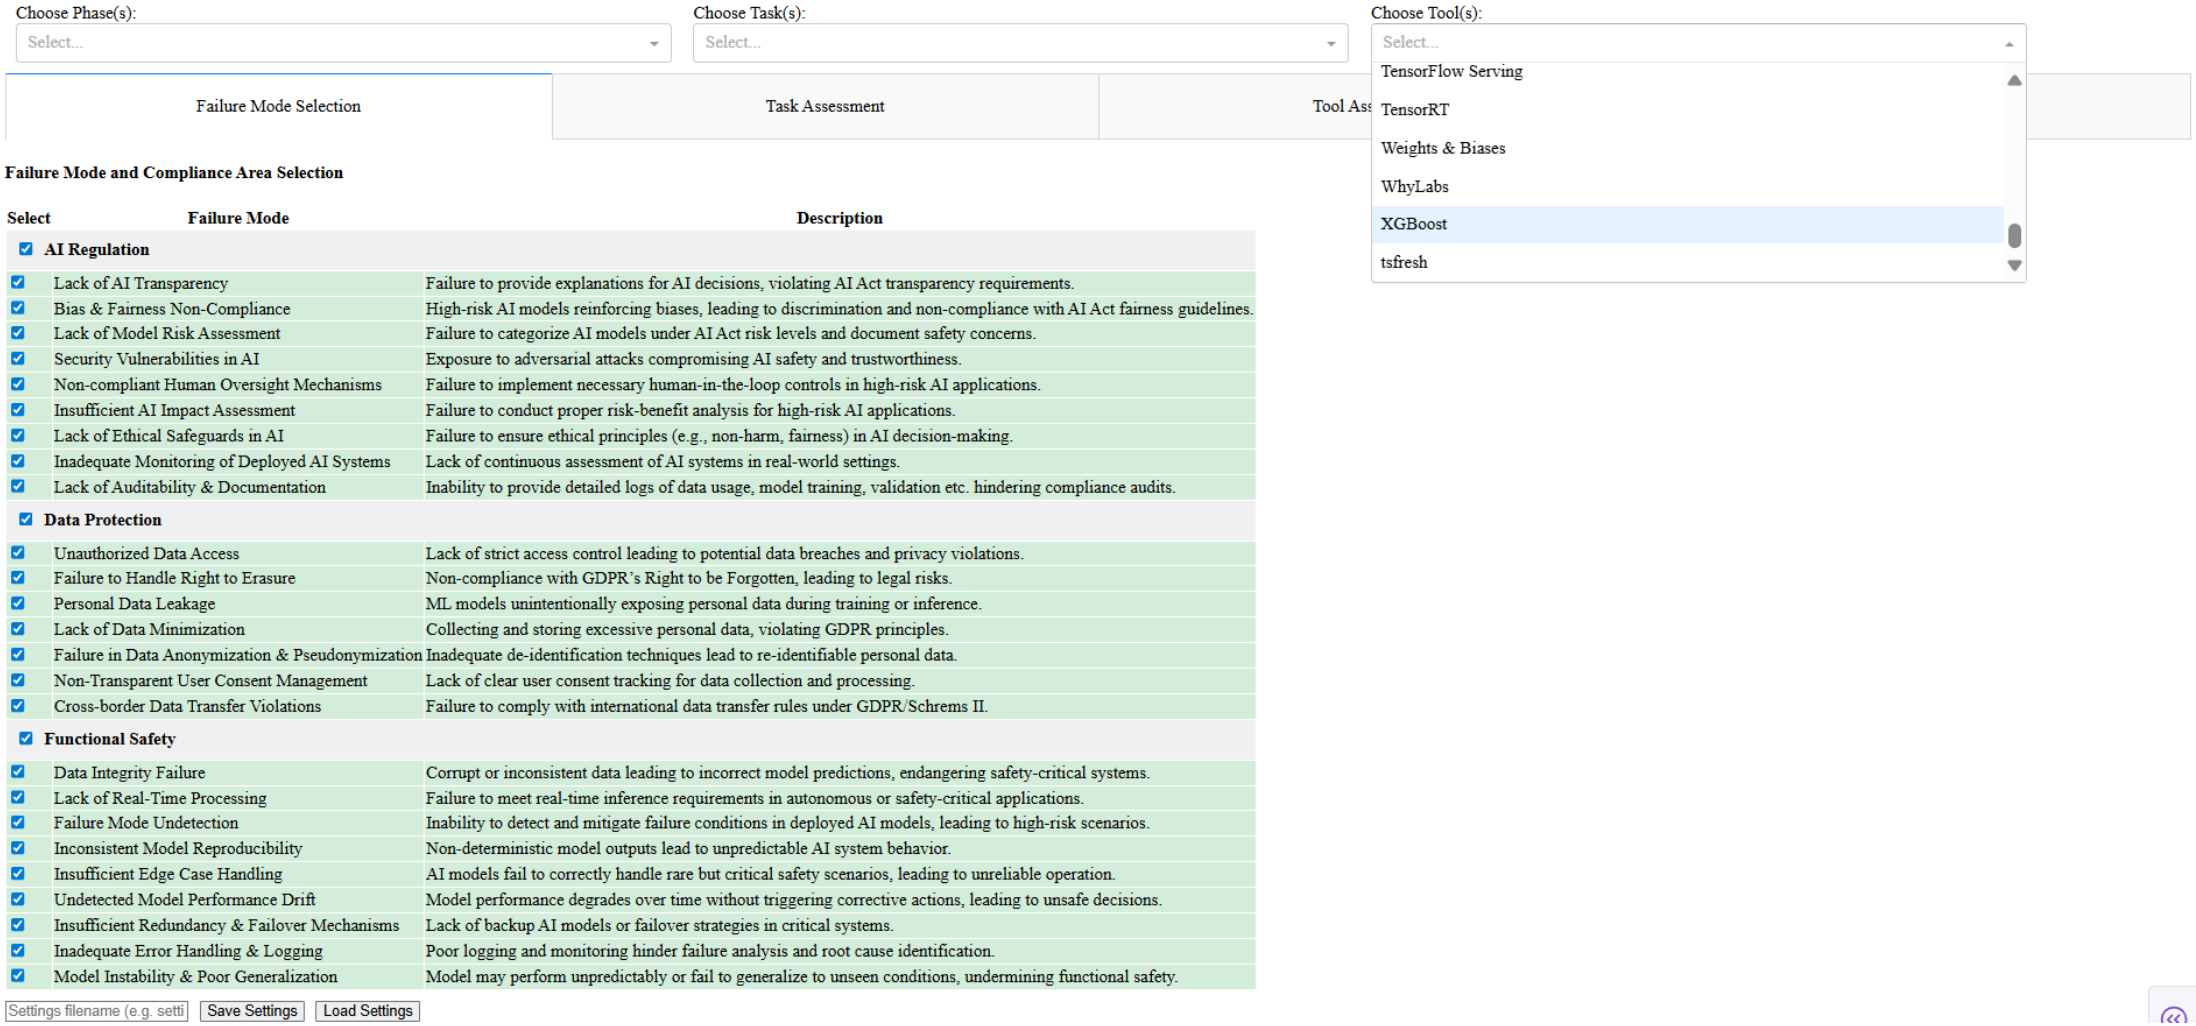

AssessML: Auswahlbereich

2. Weg: Werkzeuge

Automotive Quality Institute

Automatische Ausgabe der zugeordneten Phasen und Aufgaben

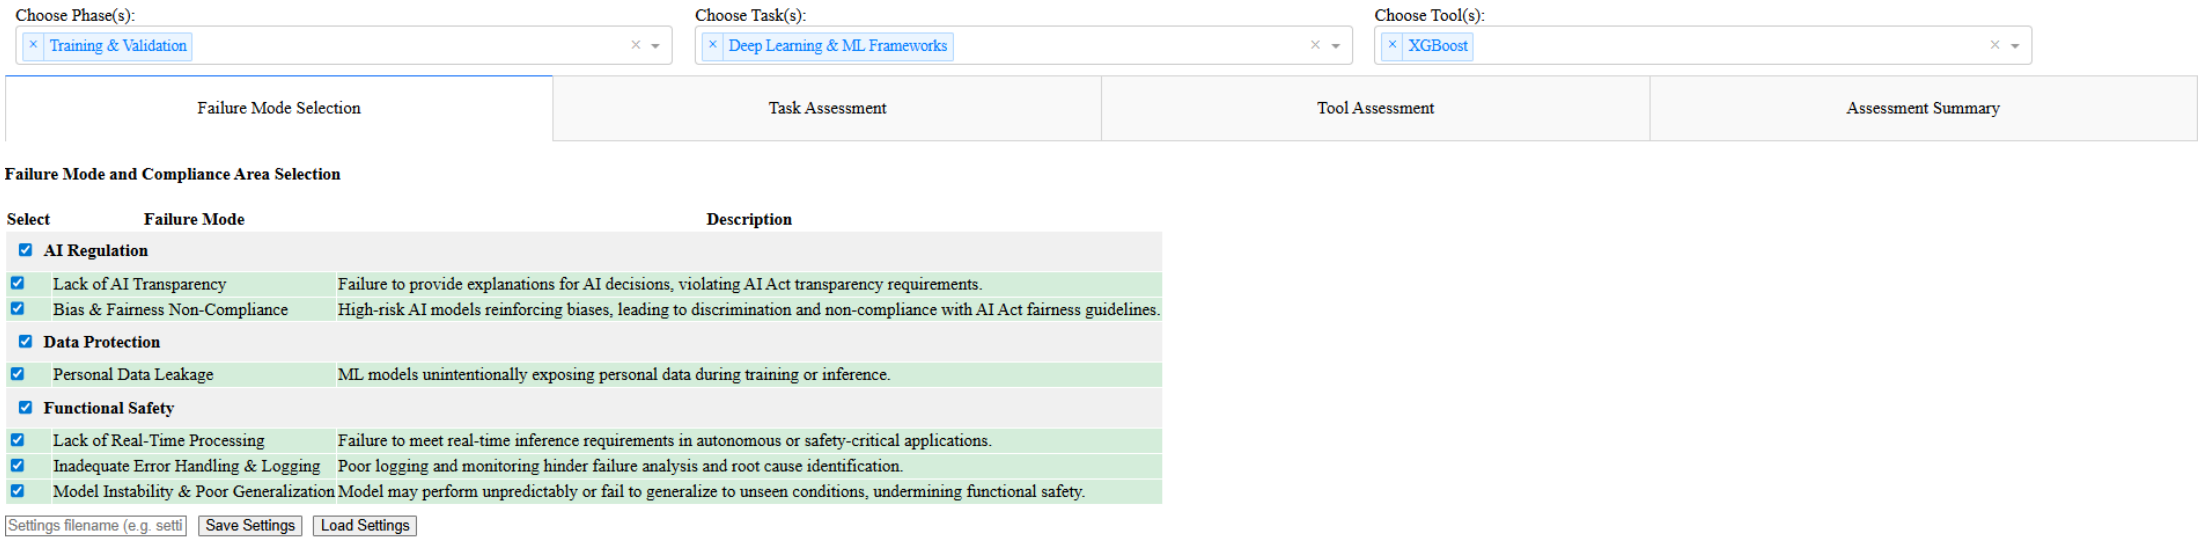

Nachdem der Tab „Werkzeuge“ durchgegangen wird, zeigt das Dashboard alle Fehlerzustände an, die dem gewählten Werkzeug zugeordnet sind. → Es erfolgt eine spezifische Einschränkung der Fehlerzustände!

AssessML: Auswahlbereich

Hinweis

Auch eine Mehrfachauswahl ist möglich, dies gilt für **beide** Wege!

1. Weg: Phasen und Aufgaben

Werden mehrere Phasen und Aufgaben ausgewählt, werden die Fehlerzustände angezeigt, die für alle ausgewählten Phasen und Aufgaben relevant sind.

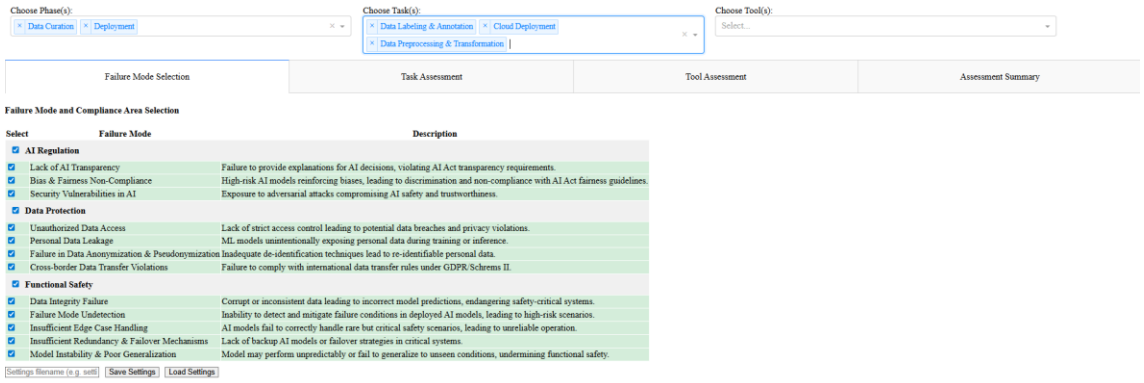

Es erfolgt eine Einschränkung der möglichen Fehlerzustände!

2. Weg: Werkzeuge

Werden mehrere Werkzeuge ausgewählt, werden die Fehlerzustände angezeigt, die für alle ausgewählten Werkzeuge relevant sind.

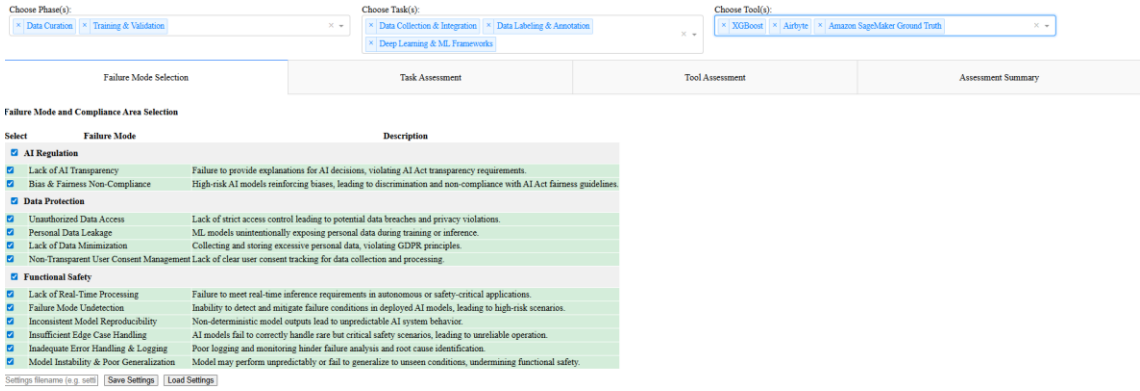

Es erfolgt eine spezifische Einschränkung der Fehlerzustände!

1. Ermittlung von Risiken in den Entwicklungsaufgaben

1.2 Auswahl der relevanten Konformitätsbereiche und Fehlerzustände

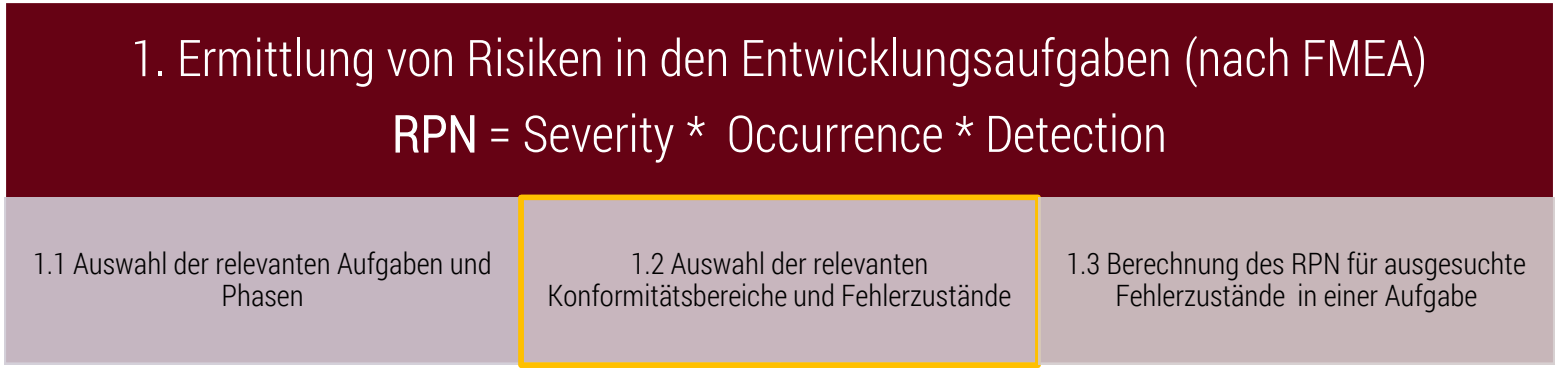

AssessML: Auswahl der Fehlerzustände

AQI | Automotive Quality Institute

Aufbau

Failure Mode Selection | Task Assessment | Tool Assessment | Assessment Summary

Failure Mode and Compliance Area Selection

Select	Failure Mode	Description
☑	**AI Regulation**	
☑	Lack of AI Transparency	Failure to provide explanations for AI decisions, violating AI Act transparency requirements.
☑	Bias & Fairness Non-Compliance	High-risk AI models reinforcing biases, leading to discrimination and non-compliance with AI Act fairness guidelines.
☑	Lack of Model Risk Assessment	Failure to categorize AI models under AI Act risk levels and document safety concerns.
☑	Security Vulnerabilities in AI	Exposure to adversarial attacks compromising AI safety and trustworthiness.
☑	Non-compliant Human Oversight Mechanisms	Failure to implement necessary human-in-the-loop controls in high-risk AI applications.
☑	Insufficient AI Impact Assessment	Failure to conduct proper risk-benefit analysis for high-risk AI applications.
☑	Lack of Ethical Safeguards in AI	Failure to ensure ethical principles (e.g., non-harm, fairness) in AI decision-making.
☑	Inadequate Monitoring of Deployed AI Systems	Lack of continuous assessment of AI systems in real-world settings.
☑	Lack of Auditability & Documentation	Inability to provide detailed logs of data usage, model training, validation etc. hindering compliance audits.
☑	**Data Protection**	
☑	Unauthorized Data Access	Lack of strict access control leading to potential data breaches and privacy violations.
☑	Failure to Handle Right to Erasure	Non-compliance with GDPR's Right to be Forgotten, leading to legal risks.
☑	Personal Data Leakage	ML models unintentionally exposing personal data during training or inference.
☑	Lack of Data Minimization	Collecting and storing excessive personal data, violating GDPR principles.
☑	Failure in Data Anonymization & Pseudonymization	Inadequate de-identification techniques lead to re-identifiable personal data.
☑	Non-Transparent User Consent Management	Lack of clear user consent tracking for data collection and processing.
☑	Cross-border Data Transfer Violations	Failure to comply with international data transfer rules under GDPR/Schrems II.
☑	**Functional Safety**	
☑	Data Integrity Failure	Corrupt or inconsistent data leading to incorrect model predictions, endangering safety-critical systems.
☑	Lack of Real-Time Processing	Failure to meet real-time inference requirements in autonomous or safety-critical applications.
☑	Failure Mode Undetection	Inability to detect and mitigate failure conditions in deployed AI models, leading to high-risk scenarios.
☑	Inconsistent Model Reproducibility	Non-deterministic model outputs lead to unpredictable AI system behavior.
☑	Insufficient Edge Case Handling	AI models fail to correctly handle rare but critical safety scenarios, leading to unreliable operation.
☑	Undetected Model Performance Drift	Model performance degrades over time without triggering corrective actions, leading to unsafe decisions.
☑	Insufficient Redundancy & Failover Mechanisms	Lack of backup AI models or failover strategies in critical systems.
☑	Inadequate Error Handling & Logging	Poor logging and monitoring hinder failure analysis and root cause identification.
☑	Model Instability & Poor Generalization	Model may perform unpredictably or fail to generalize to unseen conditions, undermining functional safety.

Der Bereich Bewertung unterteilt sich in die vier Slides:

- Failure Mode Selection (Auflistung der Fehlerzustände),
- Task Assessment (Ermittlung von Risiken in den Entwicklungsaufgaben),
- Tool Assessment (Qualifizierungsbedarfs für KI-Werkzeuge) und
- Assessment Summery (Qualifizierungs-zusammenfassung auf Basis des RPN und des TCL)

AssessML: Auswahl der Fehlerzustände

AQI | Automotive Quality Institute

Feinauswahl - Failure Mode Overview

Failure Mode Selection | Task Assessment | Tool Assessment | Assessment Summary

Failure Mode and Compliance Area Selection

Select	Failure Mode	Description
☑	**AI Regulation**	
☑	Lack of AI Transparency	Failure to provide explanations for AI decisions, violating AI Act transparency requirements.
☑	Bias & Fairness Non-Compliance	High-risk AI models reinforcing biases, leading to discrimination and non-compliance with AI Act fairness guidelines.
☑	Lack of Model Risk Assessment	Failure to categorize AI models under AI Act risk levels and document safety concerns.
☑	Security Vulnerabilities in AI	Exposure to adversarial attacks compromising AI safety and trustworthiness.
☑	Non-compliant Human Oversight Mechanisms	Failure to implement necessary human-in-the-loop controls in high-risk AI applications.
☑	Insufficient AI Impact Assessment	Failure to conduct proper risk-benefit analysis for high-risk AI applications.
☑	Lack of Ethical Safeguards in AI	Failure to ensure ethical principles (e.g., non-harm, fairness) in AI decision-making.
☑	Inadequate Monitoring of Deployed AI Systems	Lack of continuous assessment of AI systems in real-world settings.
☑	Lack of Auditability & Documentation	Inability to provide detailed logs of data usage, model training, validation etc. hindering compliance audits.
☑	**Data Protection**	
☑	Unauthorized Data Access	Lack of strict access control leading to potential data breaches and privacy violations.
☑	Failure to Handle Right to Erasure	Non-compliance with GDPR's Right to be Forgotten, leading to legal risks.
☑	Personal Data Leakage	ML models unintentionally exposing personal data during training or inference.
☑	Lack of Data Minimization	Collecting and storing excessive personal data, violating GDPR principles.
☑	Failure in Data Anonymization & Pseudonymization	Inadequate de-identification techniques lead to re-identifiable personal data.
☑	Non-Transparent User Consent Management	Lack of clear user consent tracking for data collection and processing.
☑	Cross-border Data Transfer Violations	Failure to comply with international data transfer rules under GDPR/Schrems II.
☑	**Functional Safety**	
☑	Data Integrity Failure	Corrupt or inconsistent data leading to incorrect model predictions, endangering safety-critical systems.
☑	Lack of Real-Time Processing	Failure to meet real-time inference requirements in autonomous or safety-critical applications.
☑	Failure Mode Undetection	Inability to detect and mitigate failure conditions in deployed AI models, leading to high-risk scenarios.
☑	Inconsistent Model Reproducibility	Non-deterministic model outputs lead to unpredictable AI system behavior.
☑	Insufficient Edge Case Handling	AI models fail to correctly handle rare but critical safety scenarios, leading to unreliable operation.
☑	Undetected Model Performance Drift	Model performance degrades over time without triggering corrective actions, leading to unsafe decisions.
☑	Insufficient Redundancy & Failover Mechanisms	Lack of backup AI models or failover strategies in critical systems.
☑	Inadequate Error Handling & Logging	Poor logging and monitoring hinder failure analysis and root cause identification.
☑	Model Instability & Poor Generalization	Model may perform unpredictably or fail to generalize to unseen conditions, undermining functional safety.

Der Bereich Failure Mode Selection zeigt:

- Auflistung aller Fehlerzustände,
- Erklärung für jeden Fehlerzustand

und dient zur Auswahl der gesuchten/ benötigten Fehlerzustände der drei Kompatibilitätsgebiete.

AssessML: Auswahl der Fehlerzustände

AQI | Automotive Quality Institute

Feinauswahl - Failure Mode Overview

Zur detaillierten Suche kann der Nutzer mit Hilfe der „Select-Kästchen“ weitere Filterungen vornehmen

- Nimmt man eine Auswahl für die einzelnen Fehlerzustände vor, werden die nicht weiter berücksichtigten Modi **weiß** hinterlegt.
- Nimmt man eine Auswahl für einen gesamten Kompatibilitätsgebiet vor, wird das nicht weiter berücksichtigte Gebiet **grau** hinterlegt.

Auswahl der Fehlerzustände über an-/abklicken der „Select-Kästchen“ je Fehlerzustände und/oder je Kompatibilitätsgebiete

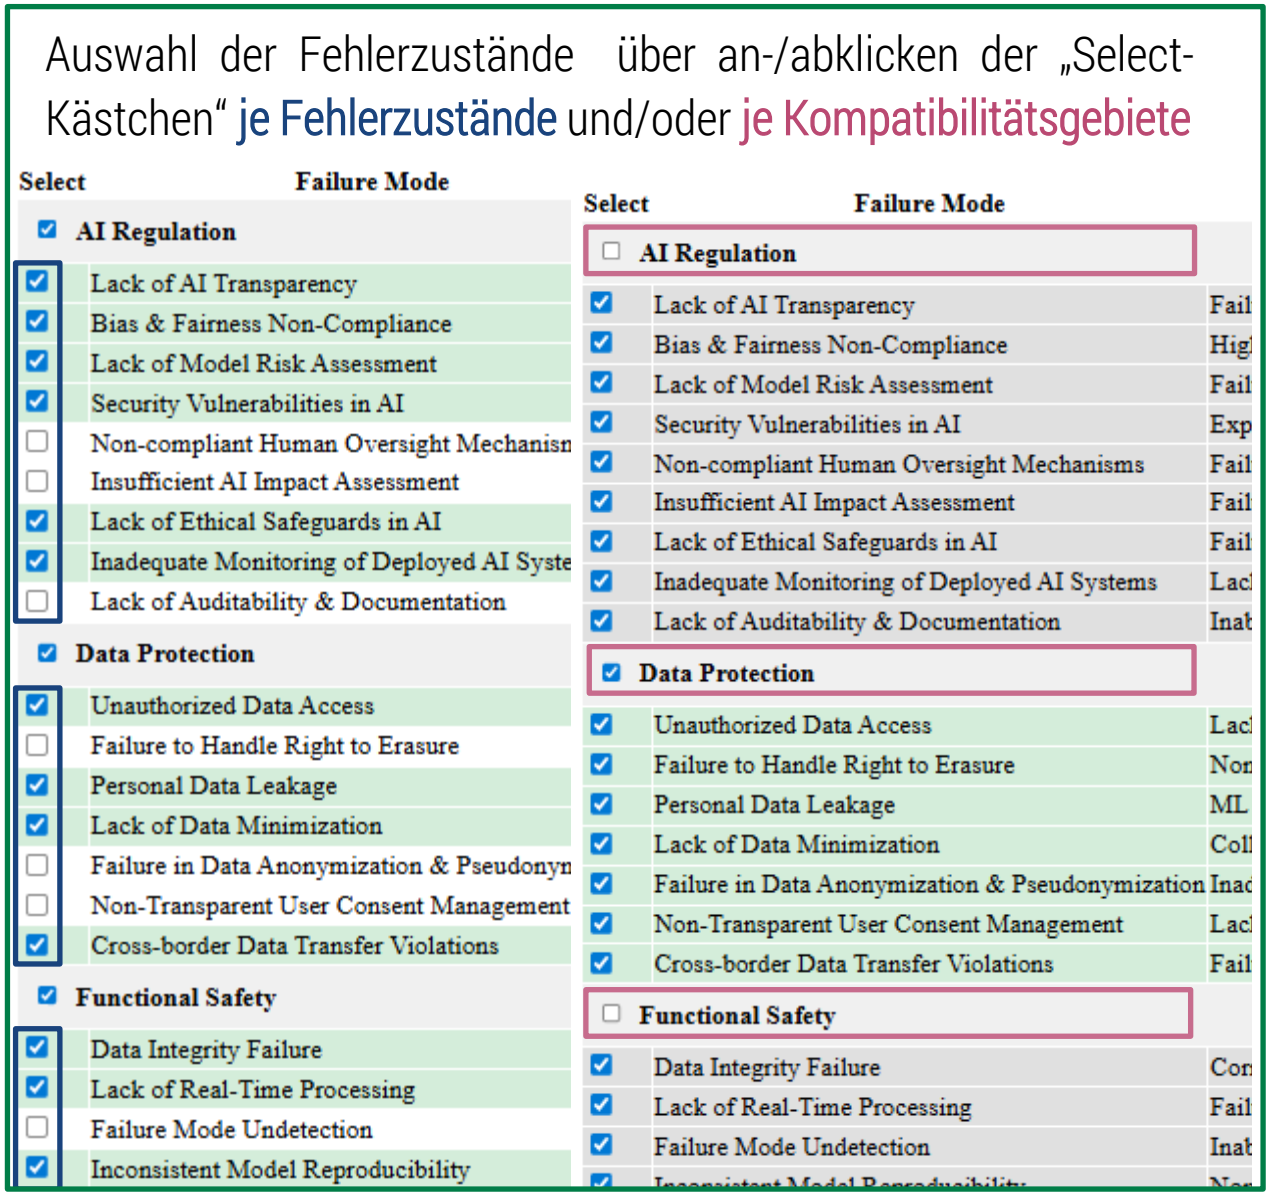

1. Ermittlung von Risiken in den Entwicklungsaufgaben

1.3 Berechnung des RPN für ausgesuchte Fehlerzustände in einer Aufgabe

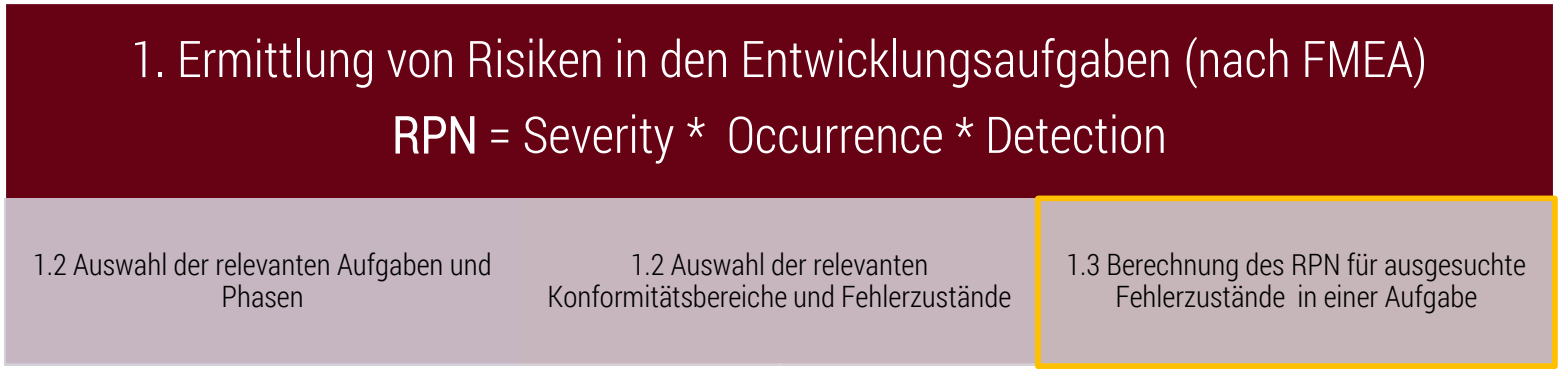

AssessML: Bewertung der Fehlerzustände

Task Assessment - Berechnung des RPN für ausgesuchte Fehlerzustände

Der Bereich Task Assessment dient zur Berechnung der Risikoprioritätskennzahl **(RPN)** je ausgewähltem Fehlerzustand und/oder Kompatibilitätsgebiet.

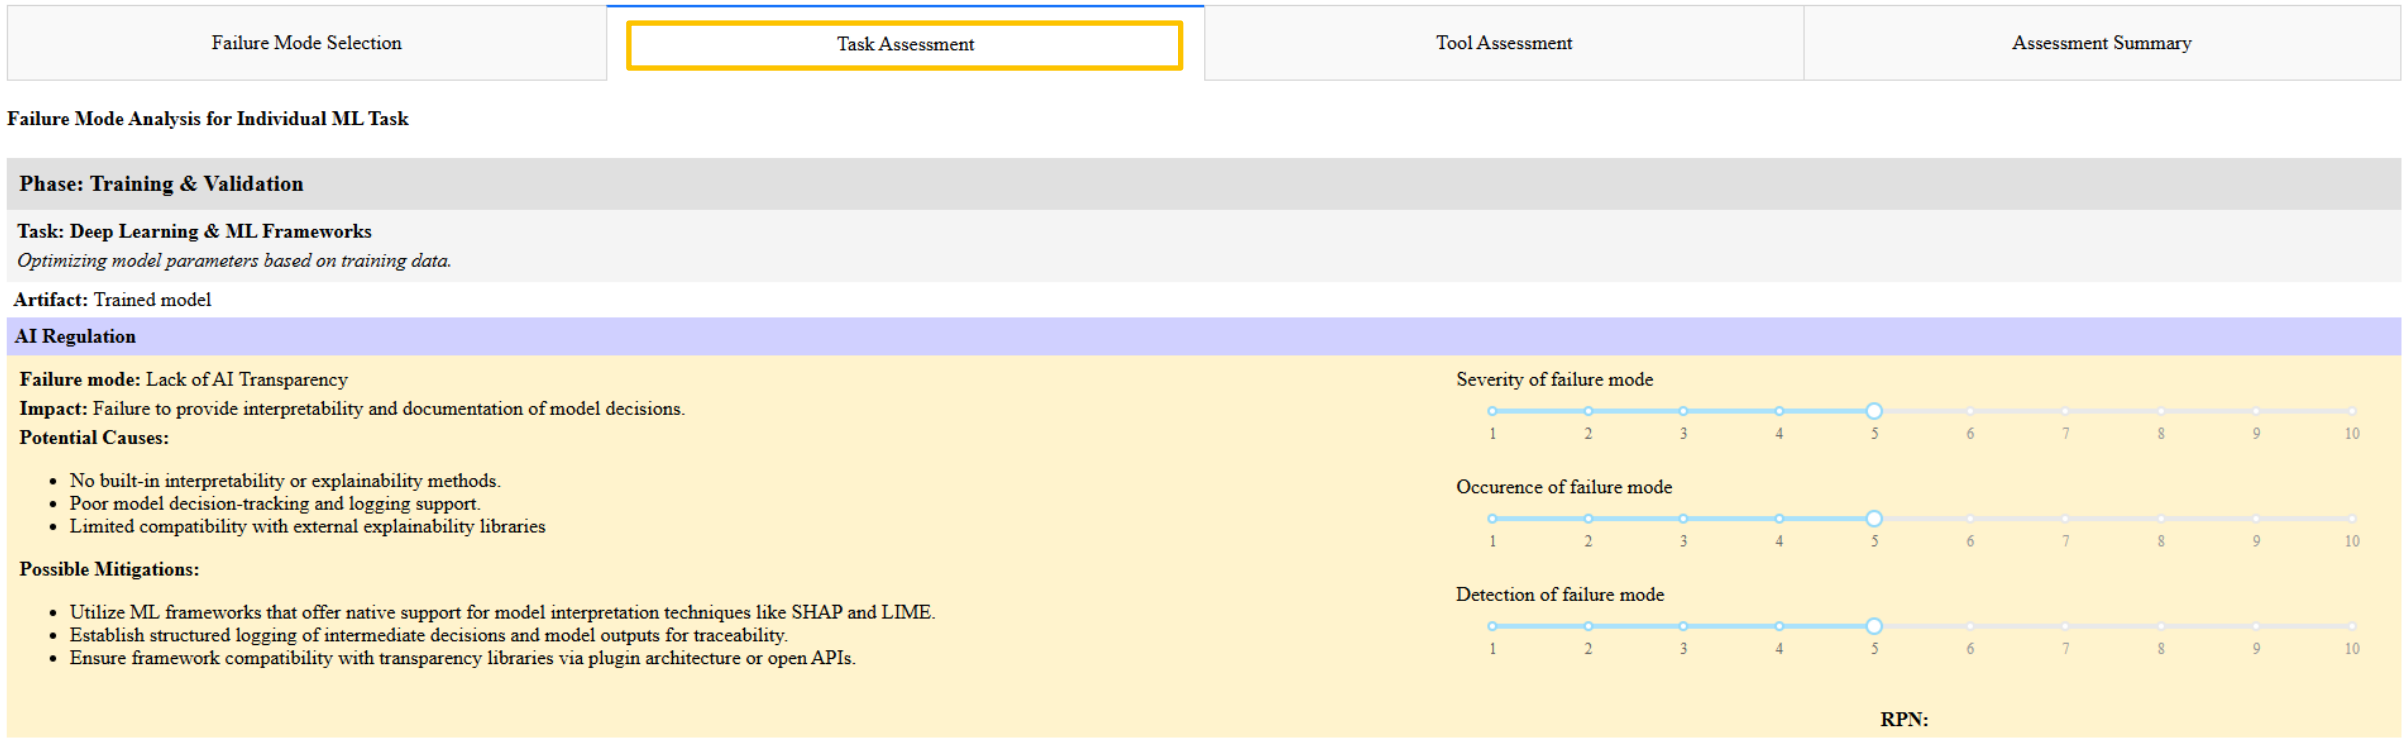

AssessML: Bewertung der Fehlerzustände

Task Assessment - Berechnung des RPN für ausgesuchte Fehlerzustände

Der RPN bildet die Summe der drei Kennziffern:

- Severity (Bedeutung der Fehlerfolge),
- Occurence (Auftretenswahrscheinlichkeit der Fehlerursache) und
- Detection (Entdeckungswahrscheinlichkeit des Fehlers oder seiner Ursache)

RPN = Severity * Occurrence * Detection

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

Risk of Deep Learning & ML Frameworks in AI Regulation

Failure mode: Lack of AI Transparency: Failure to provide interpretability and documentation of model decisions.

Potential Causes:

- No built-in interpretability or explainability methods.
- Poor model decision-tracking and logging support.
- Limited compatibility with external explainability libraries

Possible Mitigations:

- Utilize ML frameworks that offer native support for model interpretation techniques like SHAP and LIME.
- Establish structured logging of intermediate decisions and model outputs for traceability.
- Ensure framework compatibility with transparency libraries via plugin architecture or open APIs.

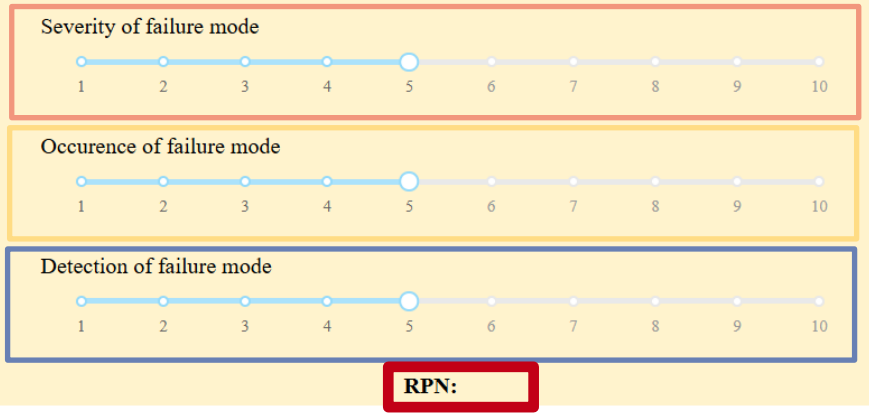

AssessML: Bewertung der Fehlerzustände

AQI | Automotive Quality Institute

Bedeutung der Fehlerfolge (Severity)

Aktion:

Bewertung der Schweregrades für die Failure-Modes durchführen, die in dem Tool den ausgewählten ML-Aufgaben zugeordnet sind.

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

Risk of Deep Learning & ML Frameworks in AI Regulation

Failure mode: Lack of AI Transparency: Failure to provide interpretability and documentation of model decisions.

Potential Causes:

- No built-in interpretability or explainability methods.
- Poor model decision-tracking and logging support.
- Limited compatibility with external explainability libraries

Possible Mitigations:

- Utilize ML frameworks that offer native support for model interpretation techniques like SHAP and LIME.
- Establish structured logging of intermediate decisions and model outputs for traceability.
- Ensure framework compatibility with transparency libraries via plugin architecture or open APIs.

Durch das bewegen des Reglers, können die Werte 1 – 3: 4 – 6; 7 – 10 bestimmt werden.

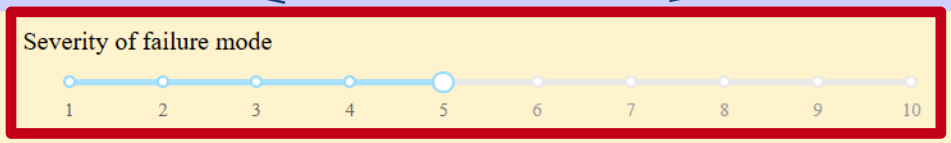

RPN:

AssessML: Bewertung der Fehlerzustände

Auftretenswahrscheinlichkeit der Fehlerursache (Occurence)

Aktion:

Bewertung der Auftrittswahrscheinlichkeit für die Failure-Modes durchführen, die in dem Tool den ausgewählten ML-Aufgaben zugeordnet sind.

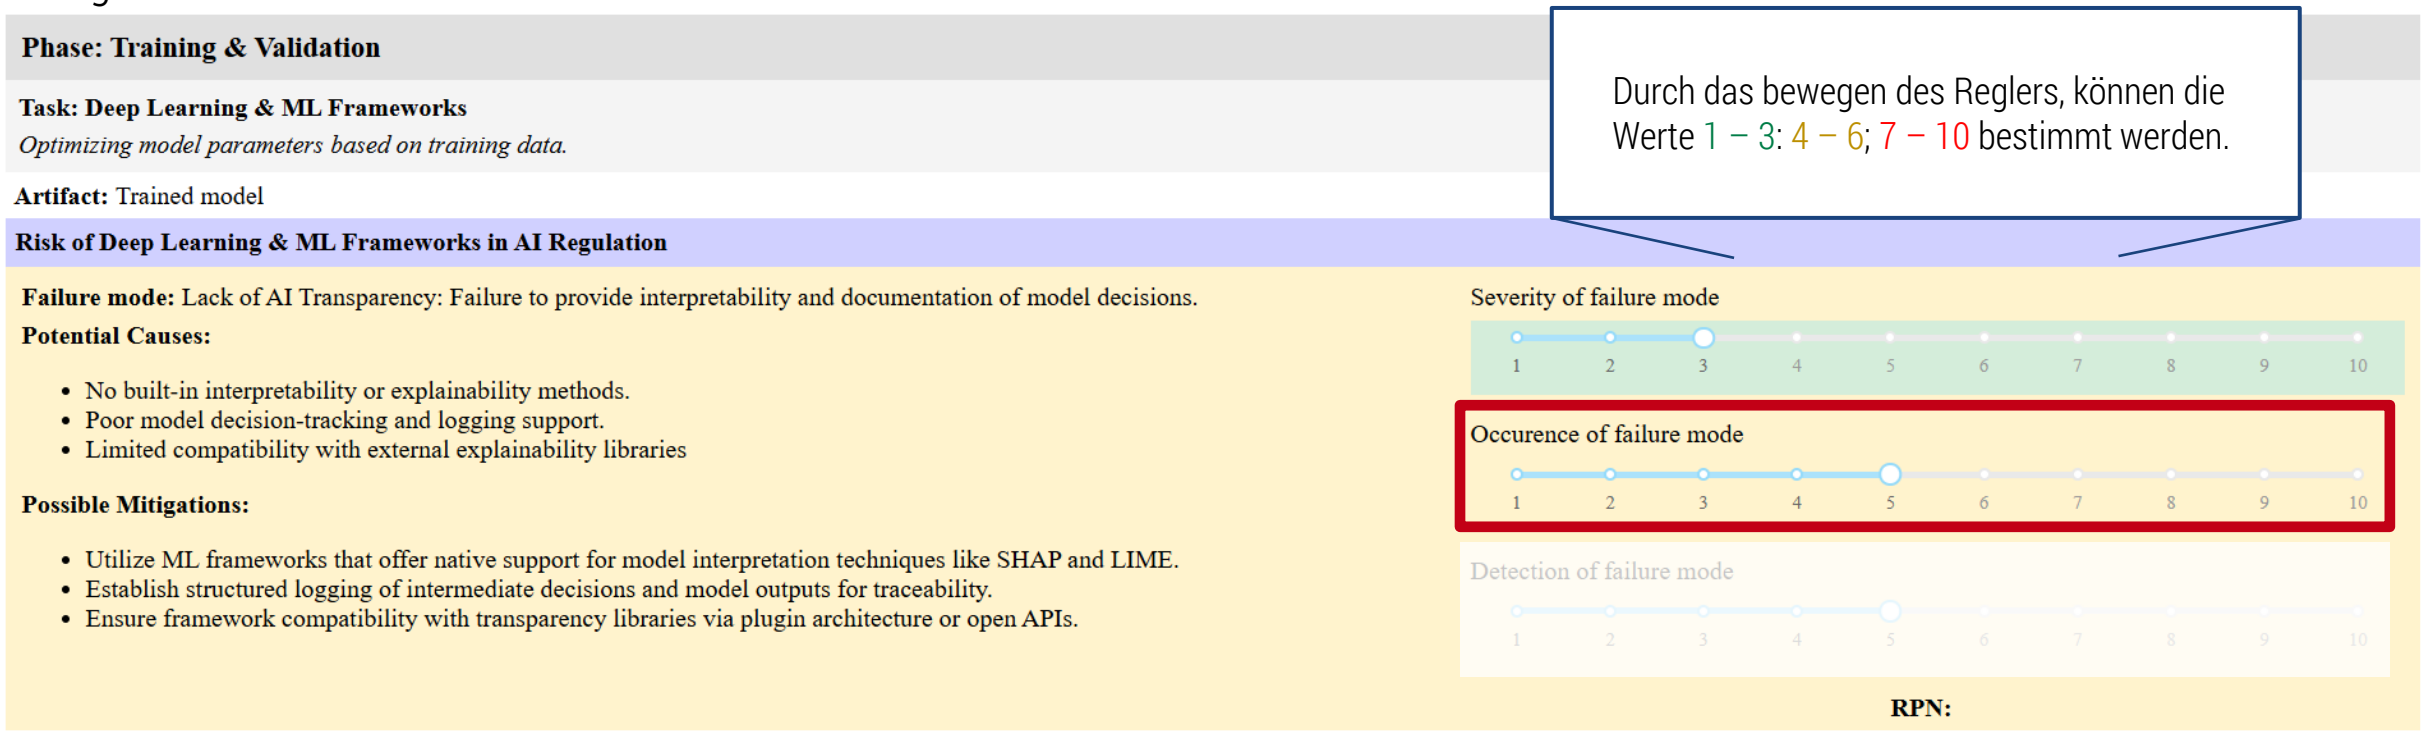

AssessML: Bewertung der Fehlerzustände

Automotive Quality Institute

Entdeckungswahrscheinlichkeit des Fehlers oder seiner Ursache (Detectability)

Aktion:

Bewertung der **Erkennbarkeit** für die Failure-Modes durchführen, die in dem Tool den ausgewählten ML-Aufgaben zugeordnet sind.

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

Risk of Deep Learning & ML Frameworks in AI Regulation

Failure mode: Lack of AI Transparency: Failure to provide interpretability and documentation of model decisions.

Potential Causes:

- No built-in interpretability or explainability methods.
- Poor model decision-tracking and logging support.
- Limited compatibility with external explainability libraries

Possible Mitigations:

- Utilize ML frameworks that offer native support for model interpretation techniques like SHAP and LIME.
- Establish structured logging of intermediate decisions and model outputs for traceability.
- Ensure framework compatibility with transparency libraries via plugin architecture or open APIs.

Durch das bewegen des Reglers, können die Werte 1 – 3: 4 – 6; 7 – 10 bestimmt werden.

Severity of failure mode

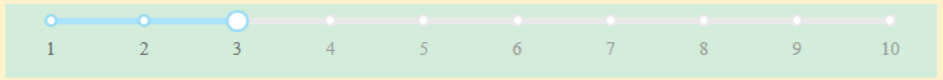

Occurence of failure mode

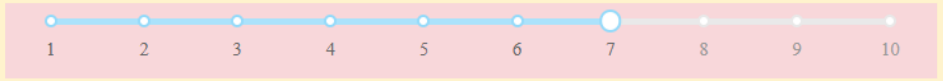

Detection of failure mode

RPN:

AssessML: Bewertung der Fehlerzustände

AQI | Automotive Quality Institute

Auswertung des RPN

Aktion:

Berechnung des RPN für die Failure-Modes, die in dem Tool den ausgewählten ML-Aufgaben zugeordnet sind.

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

Risk of Deep Learning & ML Frameworks in AI Regulation

Failure mode: Lack of AI Transparency: Failure to provide interpretability and documentation of model decisions.

Potential Causes:

- No built-in interpretability or explainability methods.
- Poor model decision-tracking and logging support.
- Limited compatibility with external explainability libraries

Possible Mitigations:

- Utilize ML frameworks that offer native support for model interpretation techniques like SHAP and LIME.
- Establish structured logging of intermediate decisions and model outputs for traceability.
- Ensure framework compatibility with transparency libraries via plugin architecture or open APIs.

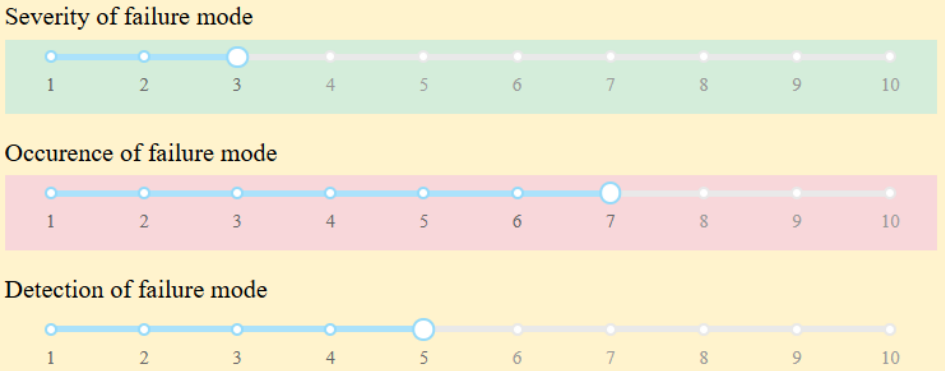

Berechnung des RPN (1 – 29; 30 – 299; 300 -1000).

AssessML: Bewertung der Fehlerzustände

Automotive Quality Institute

Task Assessment - Berechnung des RPN für ausgesuchte Fehlerzustände in einer Aufgabe

RPN = Severity * Occurrence * Detection

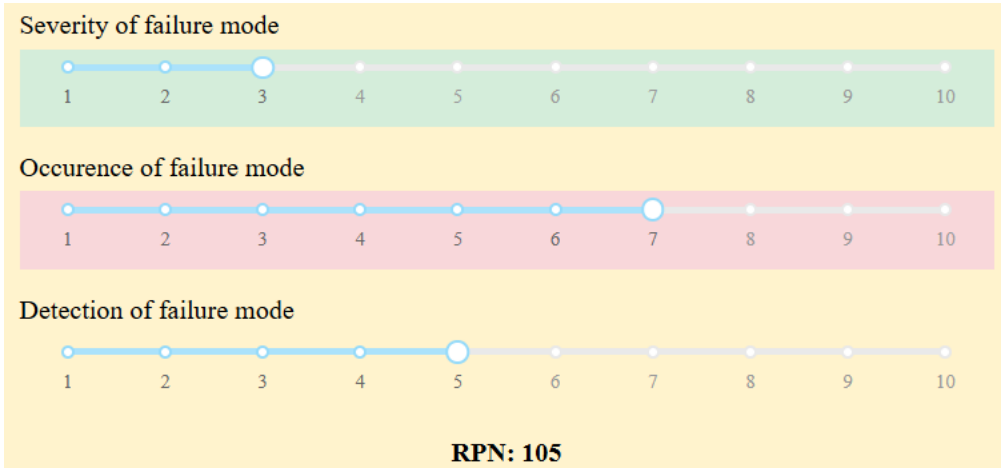

Auswertung der Risikoprioritätskennzahl (RPN):

- Niedrige RPN-Werte (RPN 1–30) weisen auf eine geringe Kritikalität hin und erfordern keine Maßnahmen.
- Mittlere RPN-Werte (RPN 31–299) weisen auf eine mittlere Kritikalität hin und erfordern daher Maßnahmen.
- Hohe Werte (RPN 300–1000) weisen auf eine hohe Kritikalität hin und erfordern umfangreichere Maßnahmen.

→ Die Ermittlung von Risiken (RPN) in den Entwicklungsaufgaben (nach FMEA) fokussiert sich auf die Ermittlung **je Use-Case**

2. Ermittlung des Qualifizierungsbedarfs für KI- Werkzeuge

2.1 Einschätzung über die Bedeutung des Werkzeugs für einen Fehler (Tool Impact)

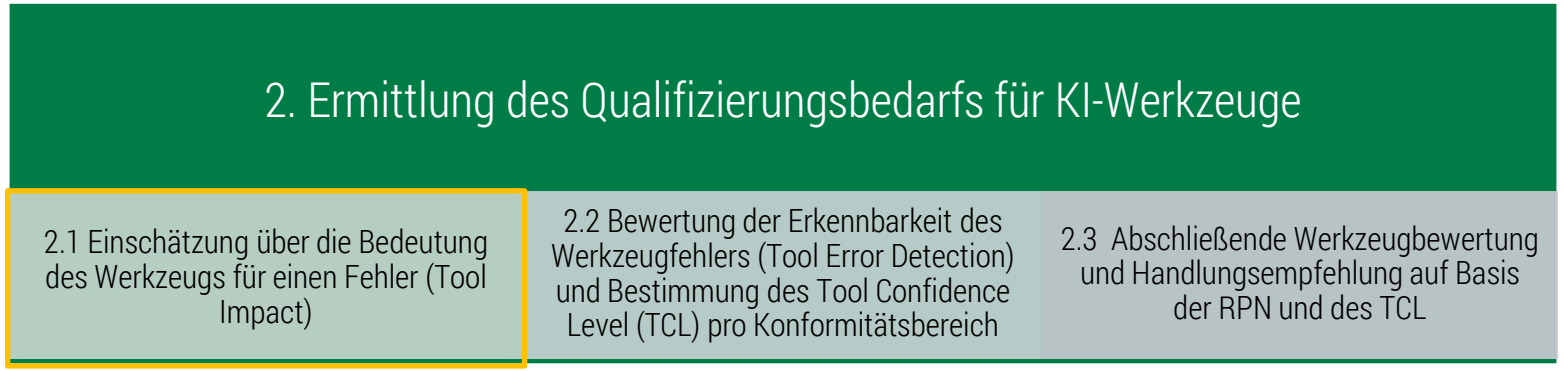

AssessML: Auswirkung eines Werkzeugfehlers

Tool Assessment - Ermittlung des Qualifizierungsbedarfs für KI-Werkzeuge

Der Bereich Tool Assessment dient zur Ermittlung des Qualifizierungsbedarfs für KI-Werkzeuge je ausgewähltem Fehlerzustnd und/oder Kompatibilitätsgebiet.

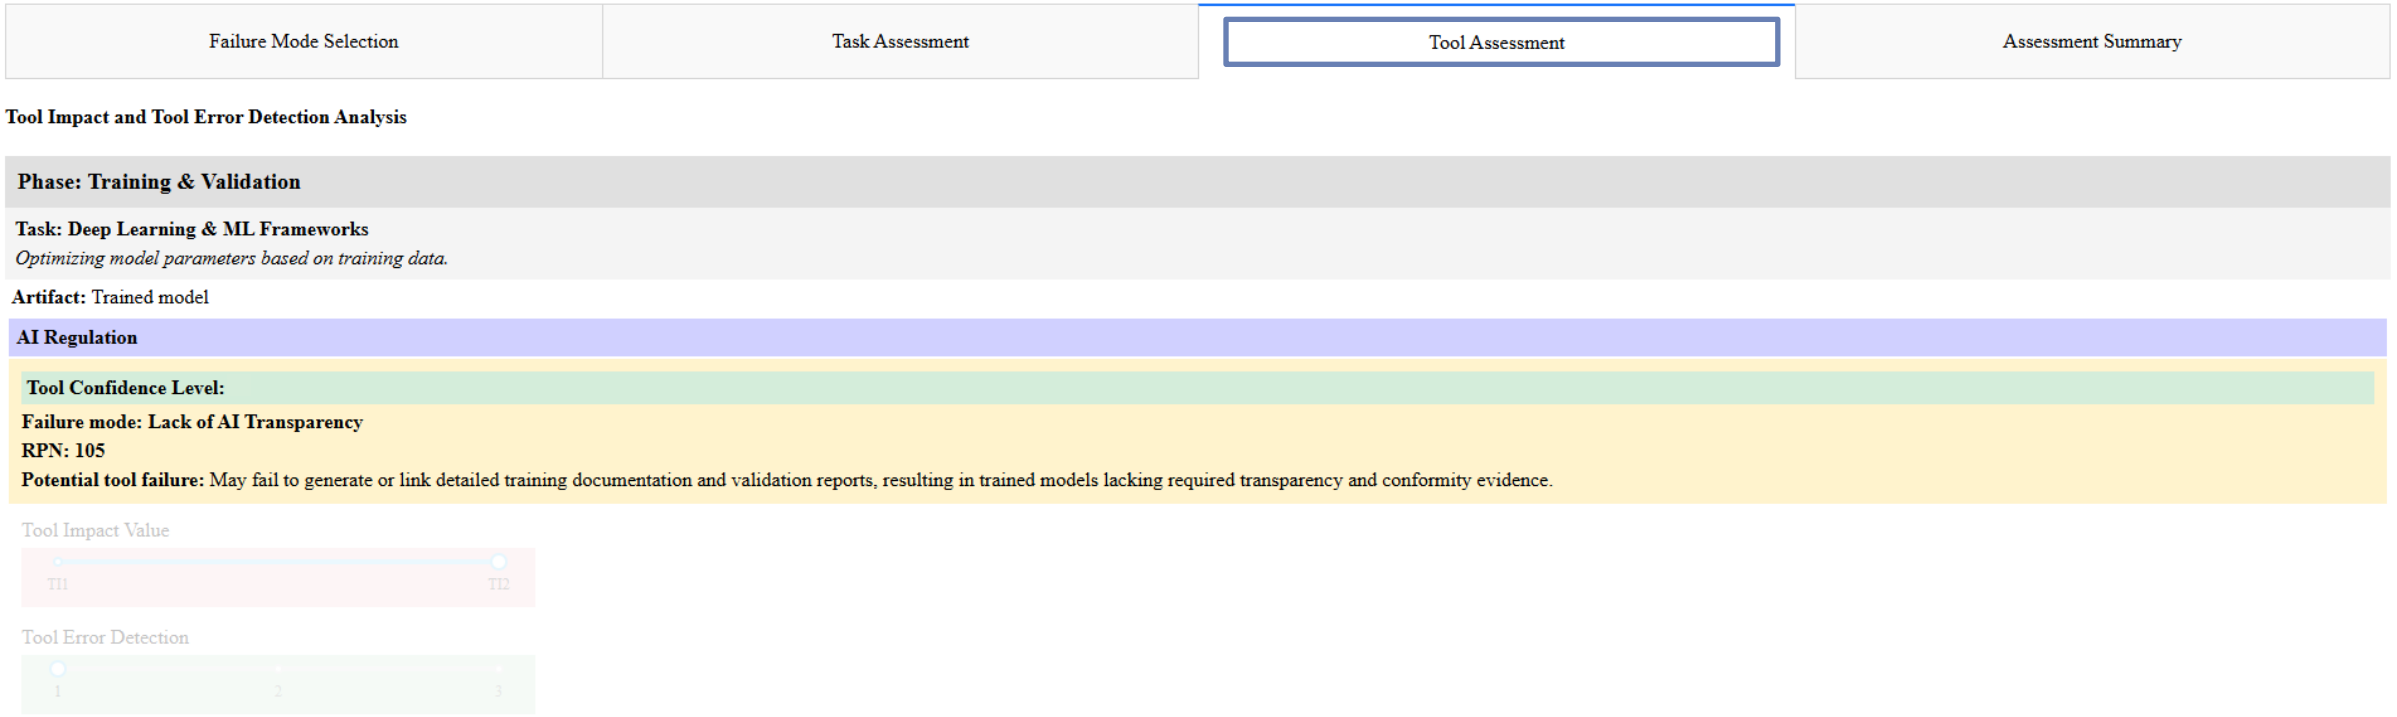

AssessML: Auswirkung eines Werkzeugfehlers

AQI | Automotive Quality Institute

Auswirkungsgrad des Werkzeuges

Failure Mode Selection | Task Assessment | **Tool Assessment** | Assessment Summary

Tool Impact and Tool Error Detection Analysis

Phase: Training & Validation

Task: Deep Learning & ML Frameworks
Optimizing model parameters based on training data.

Artifact: Trained model

AI Regulation

Tool Confidence Level:
Failure mode: Lack of AI Transparency
RPN: 105
Potential tool failure: May fail to generate or link detailed training documentation and validation reports, resulting in trained models lacking required transparency and conformity evidence.

Tool Impact Value
TI1 TI2

Tool Error Detection
1 2 3

In Anlehnung an das Kapitel 11.4.5.2 der ISO 26262:2018, wird die Bestimmung des **Tool Confidence Levels (TCL)** ermittelt, welche auf den drei folgenden Teilen basiert:

- Tool Impact (TI), beurteilt, ob ein Fehler des Tools sicherheitsrelevant sein kann,
- Tool Error Detection (TD) , beurteilt die Wahrscheinlichkeit, dass ein Fehler entdeckt wird, und resultiert im
- Tool Confidence Level (TCL), dem erforderlichen Maß an Vertrauen in das Tool (TCL1 bis TCL3).

Quelle: Eigene Darstellung nach ISO 26262:2018 Kap. 11.4.5.2

AssessML: Auswirkung eines Werkzeugfehlers

AQI Automotive Quality Institute

Einschätzung über die Bedeutung des Werkzeugs für einen Fehler (Tool Impact)

Aktion: Hat ein potenzieller Fehler des Tools Einfluss auf die Funktionalität sicherheitsrelevanter Systeme?

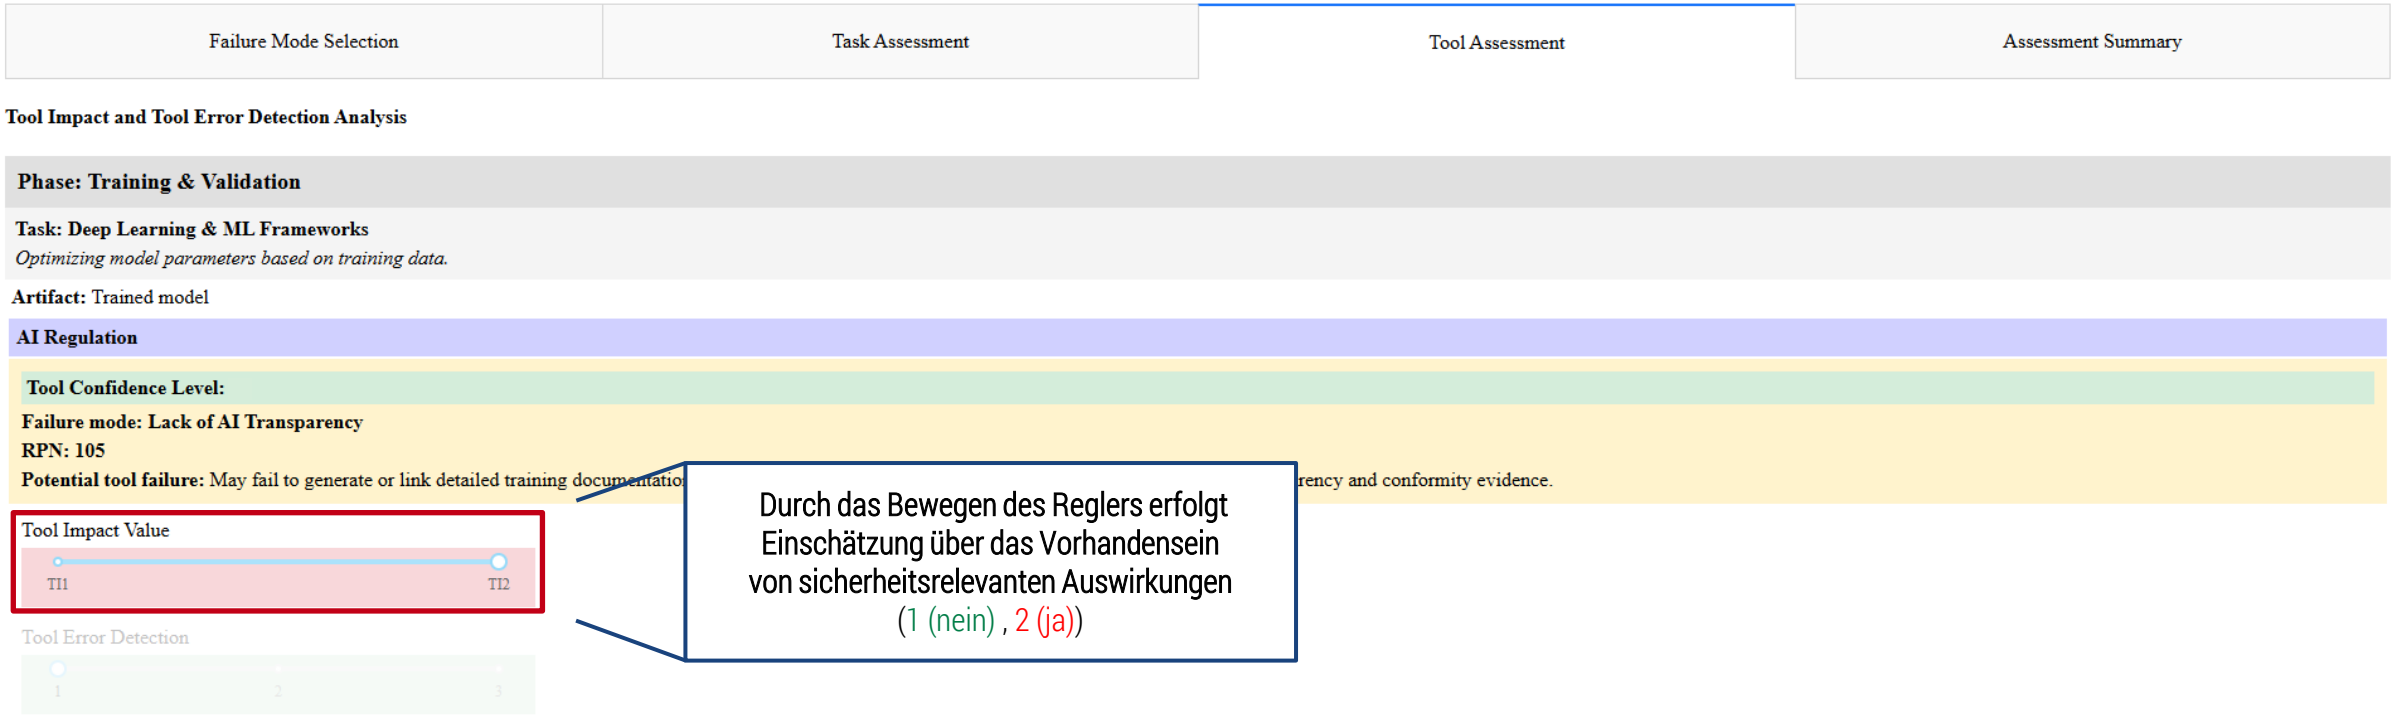

2. Ermittlung des Qualifizierungsbedarfs für KI- Werkzeuge

2.2 Bewertung der Erkennbarkeit des Werkzeugfehlers (Tool Error Detection) und TCL

AssessML: Erkennbarkeit des Werkzeugfehlers

AQI Automotive Quality Institute

Bewertung der Erkennbarkeit des Werkzeug-fehlers (Tool Error Detection)

Aktion: Wie gut können Fehler, die durch das Tool entstehen, im weiteren Entwicklungsprozess erkannt werden?

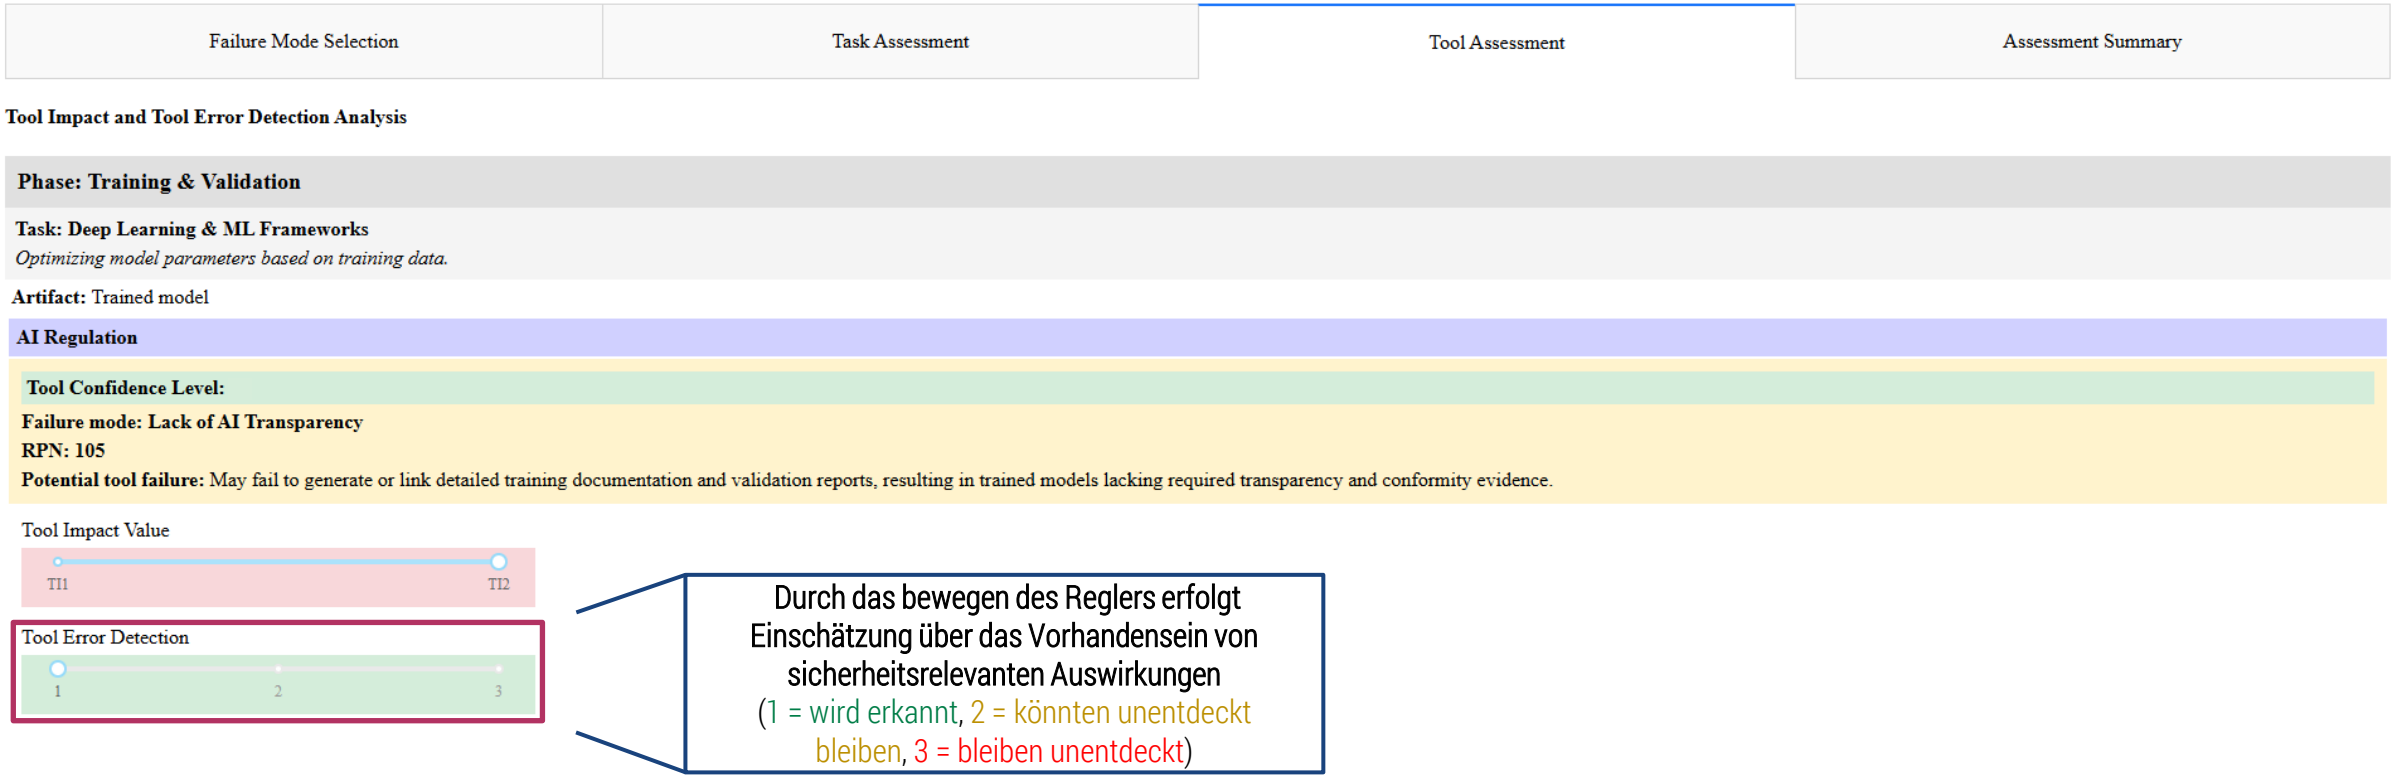

Durch das bewegen des Reglers erfolgt Einschätzung über das Vorhandensein von sicherheitsrelevanten Auswirkungen
(1 = wird erkannt, 2 = könnten unentdeckt bleiben, 3 = bleiben unentdeckt)

Hintergrund: Berechnung TCL

AQI Automotive Quality Institute

Vertrauensbedarf für die Werkzeugnutzung

Ausgangslage: Wie hoch muss das Vertrauen in das Tool sein (bzw. ist eine Toolqualifikation notwendig)?

Table 3 — Determination of the Tool Confidence Level (TCL)

		Tool error detection		
		TD1	TD2	TD3
Tool impact	TI1	TCL1	TCL1	TCL1
	TI2	TCL1	TCL2	TCL3

Quelle: ISO 26262:2018, Kap. 11.4.5.4

↓

Aspekt	Bild	Textbeschreibung
Ziel	***Zuordnung des passenden Tool Confidence Levels (TCL)*** *auf Basis von Tool Impact (TI) und Tool Error Detection (TD)*	*Festlegen,* ***wie hoch das Vertrauen*** *in das Tool sein muss (bzw. ob eine Toolqualifikation notwendig ist)*
TCL1 (niedrig)	▪ Tool hat **keinen sicherheitsrelevanten Einfluss (TI1)** oder ▪ Fehler werden **sicher erkannt (TI2 + TD1)** → **Keine Toolqualifikation notwendig**	▪ **Geringe Bedeutung** für Produktqualität ▪ Keine Toolqualifikation notwendig → Vertrauen in Toolverhalten aus Sicht ISO 26262 **nicht kritisch**
TCL2 (mittel)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **nicht sicher erkennbar (TD2)**	▪ Tool **wichtig für Produktqualität** ▪ Toolqualifikation erforderlich ▪ Anforderungen abhängig vom ASIL-Level
TCL3 (hoch)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **bleiben unentdeckt (TD3)**	▪ **Hohe Bedeutung** für Produktqualität ▪ **Toolqualifikation zwingend nötig**, hohe Anforderungen ▪ Unterschiede zwischen TCL2 und TCL3 sind methodisch relevant, aber nicht dramatisch (je nach ASIL)

Hintergrund: Berechnung TCL

AQI Automotive Quality Institute

Vertrauensbedarf für die Werkzeugnutzung

Ausgangslage: Wie hoch muss das Vertrauen in das Tool sein (bzw. ist eine Toolqualifikation notwendig)?

Table 3 — Determination of the Tool Confidence Level (TCL)

		Tool error detection		
		TD1	TD2	TD3
Tool impact	TI1	TCL1	TCL1	TCL1
	TI2	TCL1	TCL2	TCL3

Quelle: ISO 26262:2018, Kap. 11.4.5.4

↓

Aspekt	Bild	Textbeschreibung
Ziel	***Zuordnung des passenden Tool Confidence Levels (TCL)** auf Basis von Tool Impact (TI) und Tool Error Detection (TD)*	*Festlegen, **wie hoch das Vertrauen** in das Tool sein muss (bzw. ob eine Toolqualifikation notwendig ist)*
TCL1 (niedrig)	▪ Tool hat **keinen sicherheitsrelevanten Einfluss (TI1)** oder ▪ Fehler werden **sicher erkannt (TI2 + TD1)** → **Keine Toolqualifikation notwendig**	▪ **Geringe Bedeutung** für Produktqualität ▪ Keine Toolqualifikation notwendig → Vertrauen in Toolverhalten aus Sicht ISO 26262 **nicht kritisch**
TCL2 (mittel)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **nicht sicher erkennbar (TD2)**	▪ Tool **wichtig für Produktqualität** ▪ Toolqualifikation erforderlich ▪ Anforderungen abhängig vom ASIL-Level
TCL3 (hoch)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **bleiben unentdeckt (TD3)**	▪ **Hohe Bedeutung** für Produktqualität ▪ **Toolqualifikation zwingend nötig**, hohe Anforderungen ▪ Unterschiede zwischen TCL2 und TCL3 sind methodisch relevant, aber nicht dramatisch (je nach ASIL)

Hintergrund: Berechnung TCL

AQI | Automotive Quality Institute

Vertrauensbedarf für die Werkzeugnutzung

Ausgangslage: Wie hoch muss das Vertrauen in das Tool sein (bzw. ist eine Toolqualifikation notwendig)?

Table 3 — Determination of the Tool Confidence Level (TCL)

		Tool error detection		
		TD1	TD2	TD3
Tool impact	TI1	TCL1	TCL1	TCL1
	TI2	TCL1	TCL2	TCL3

Quelle: ISO 26262:2018, Kap. 11.4.5.4

↓

Aspekt	Bild	Textbeschreibung
Ziel	***Zuordnung des passenden Tool Confidence Levels (TCL)** auf Basis von Tool Impact (TI) und Tool Error Detection (TD)*	*Festlegen, **wie hoch das Vertrauen** in das Tool sein muss (bzw. ob eine Toolqualifikation notwendig ist)*
TCL1 (niedrig)	▪ Tool hat **keinen sicherheitsrelevanten Einfluss** (TI1) oder ▪ Fehler werden **sicher erkannt** (TI2 + TD1) → **Keine Toolqualifikation notwendig**	▪ **Geringe Bedeutung** für Produktqualität ▪ Keine Toolqualifikation notwendig → Vertrauen in Toolverhalten aus Sicht ISO 26262 **nicht kritisch**
TCL2 (mittel)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **nicht sicher erkennbar (TD2)**	▪ Tool **wichtig für Produktqualität** ▪ Toolqualifikation erforderlich ▪ Anforderungen abhängig vom ASIL-Level
TCL3 (hoch)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **bleiben unentdeckt** (TD3)	▪ **Hohe Bedeutung** für Produktqualität ▪ **Toolqualifikation zwingend nötig**, hohe Anforderungen ▪ Unterschiede zwischen TCL2 und TCL3 sind methodisch relevant, aber nicht dramatisch (je nach ASIL)

Hintergrund: Berechnung TCL

AQI Automotive Quality Institute

Vertrauensbedarf für die Werkzeugnutzung

Ausgangslage: Wie hoch muss das Vertrauen in das Tool sein (bzw. ist eine Toolqualifikation notwendig)?

Table 3 — Determination of the Tool Confidence Level (TCL)

		Tool error detection		
		TD1	TD2	TD3
Tool impact	TI1	TCL1	TCL1	TCL1
	TI2	TCL1	TCL2	TCL3

Quelle: ISO 26262:2018, Kap. 11.4.5.4

Aspekt	Bild	Textbeschreibung
Ziel	***Zuordnung des passenden Tool Confidence Levels (TCL)** auf Basis von Tool Impact (TI) und Tool Error Detection (TD)*	*Festlegen, **wie hoch das Vertrauen** in das Tool sein muss (bzw. ob eine Toolqualifikation notwendig ist)*
TCL1 (niedrig)	▪ Tool hat **keinen sicherheitsrelevanten Einfluss** (TI1) oder ▪ Fehler werden **sicher erkannt** (TI2 + TD1) → **Keine Toolqualifikation notwendig**	▪ **Geringe Bedeutung** für Produktqualität ▪ Keine Toolqualifikation notwendig → Vertrauen in Toolverhalten aus Sicht ISO 26262 **nicht kritisch**
TCL2 (mittel)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler nicht sicher erkennbar (TD2)	▪ Tool wichtig für Produktqualität ▪ Toolqualifikation erforderlich ▪ Anforderungen abhängig vom ASIL-Level
TCL3 (hoch)	▪ Tool hat sicherheitsrelevanten Einfluss (TI2) ▪ Fehler **bleiben unentdeckt** (TD3)	▪ **Hohe Bedeutung** für Produktqualität ▪ **Toolqualifikation zwingend nötig**, hohe Anforderungen ▪ Unterschiede zwischen TCL2 und TCL3 sind methodisch relevant, aber nicht dramatisch (je nach ASIL)

AssessML: Berechnung TCL

Automotive Quality Institute

Bestimmung des Tool Confidence Level (TCL)

Aktion: Wie hoch muss das Vertrauen in das Tool sein (bzw. ist eine Toolqualifikation notwendig)?

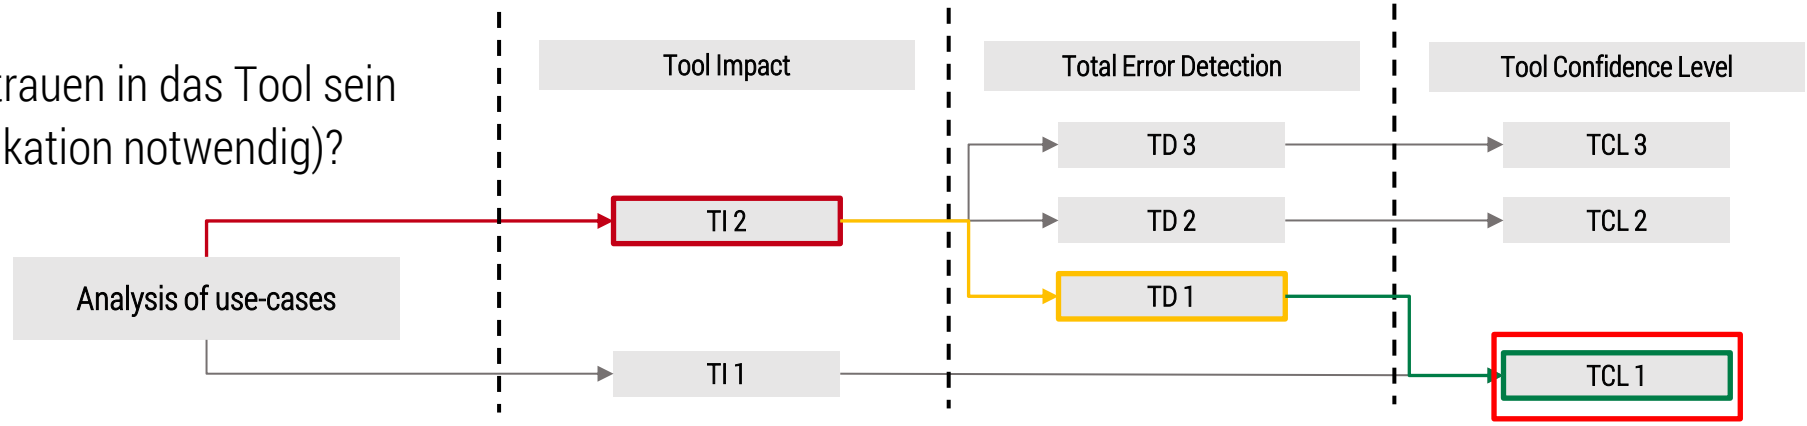

Tool Impact and Tool Error Detection Analysis

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

AI Regulation

Tool Confidence Level: 1

Failure mode: Lack of AI Transparency

RPN: 105

Potential tool failure: May fail to generate or link detailed training documentation and validation reports, resulting in trained models lacking required transparency and conformity evidence.

Berechnung des Vertrauenslevel
(1 = niedrig, 2 = mittel, 3 = hoch)

Tool Impact Value

TI1 TI2

Tool Error Detection

1 2 3

2. Ermittlung des Qualifizierungsbedarfs für KI- Werkzeuge

2.3 Werkzeugbewertung und Handlungsempfehlung auf Basis der RPN und des TCL

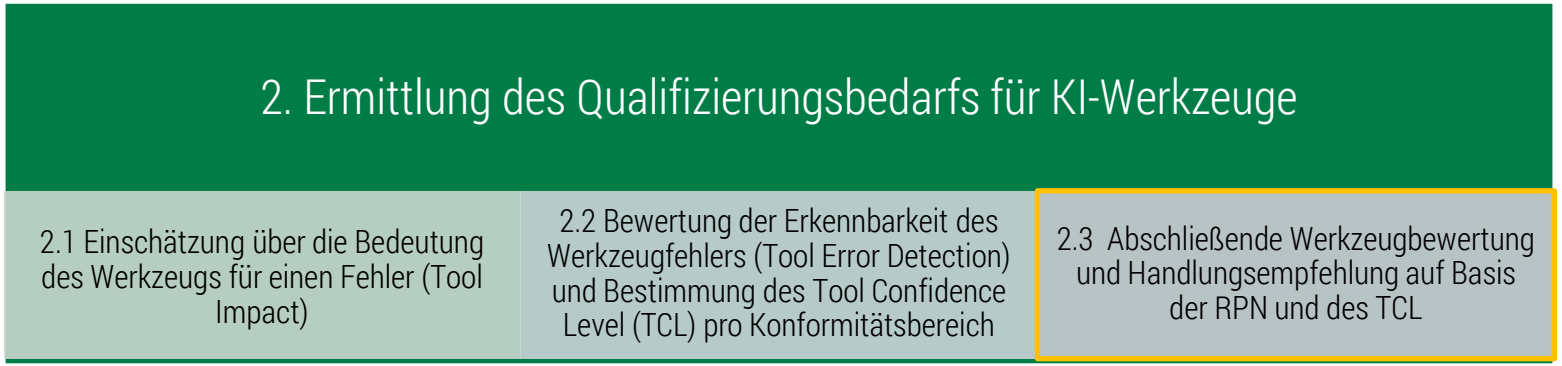

*AssessML: B*ewertung und Handlungsempfehlung

AQI Automotive Quality Institute

Assessment Summery - Qualifizierungszusammenfassung

Der Bereich Assessment Summery dient zur Bewertung und Priorisierung der Qualifizierungszusammenfassung auf Basis des RPN und des TCL für ausgewählte Fehlerzustände.

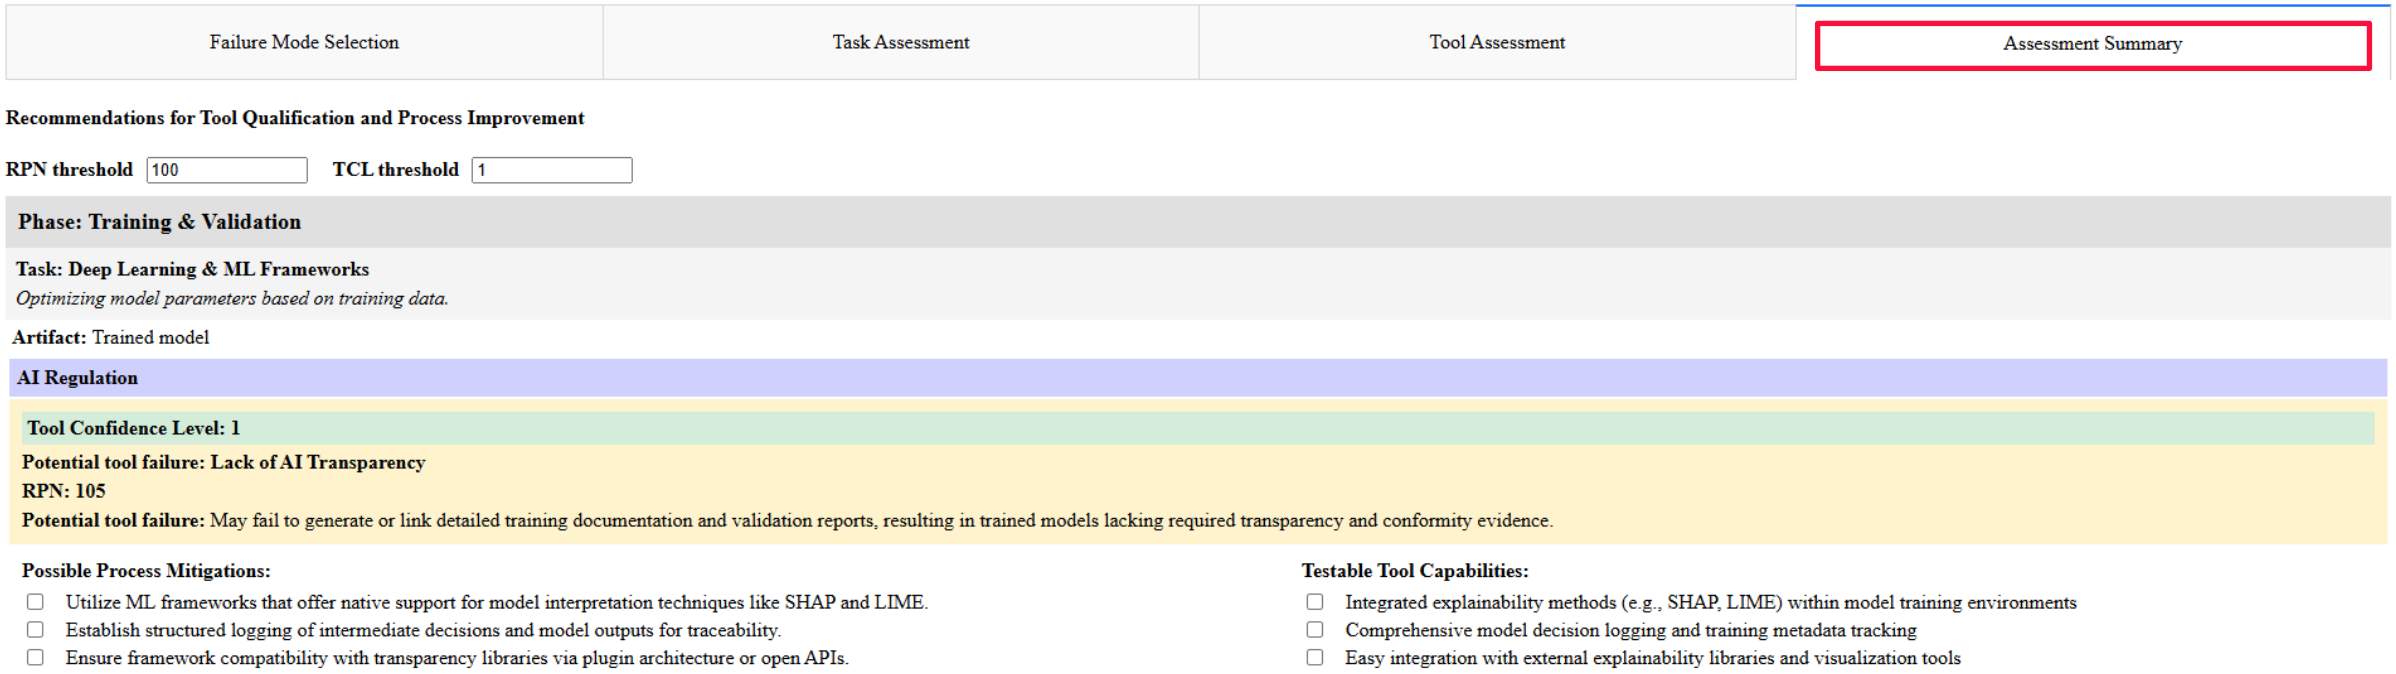

*AssessML: B*ewertung und Handlungsempfehlung

AQI | Automotive Quality Institute

Übersicht über die bestimmte Risikoprioritätskennzahl und das Werkzeugvertrauenslevel

Die Fehlerzustände können mit Hilfe der Eingaben für **Thresholds** (Schwellenwerte) gefiltert werden. Dabei können zwei verschiedene Angaben gewichtet werden:

- RPN threshold (Grenzwert für die Risikoprioritätskennzahl)
- TCL threshold (Grenzwert für das Werkzeugvertrauenslevel)

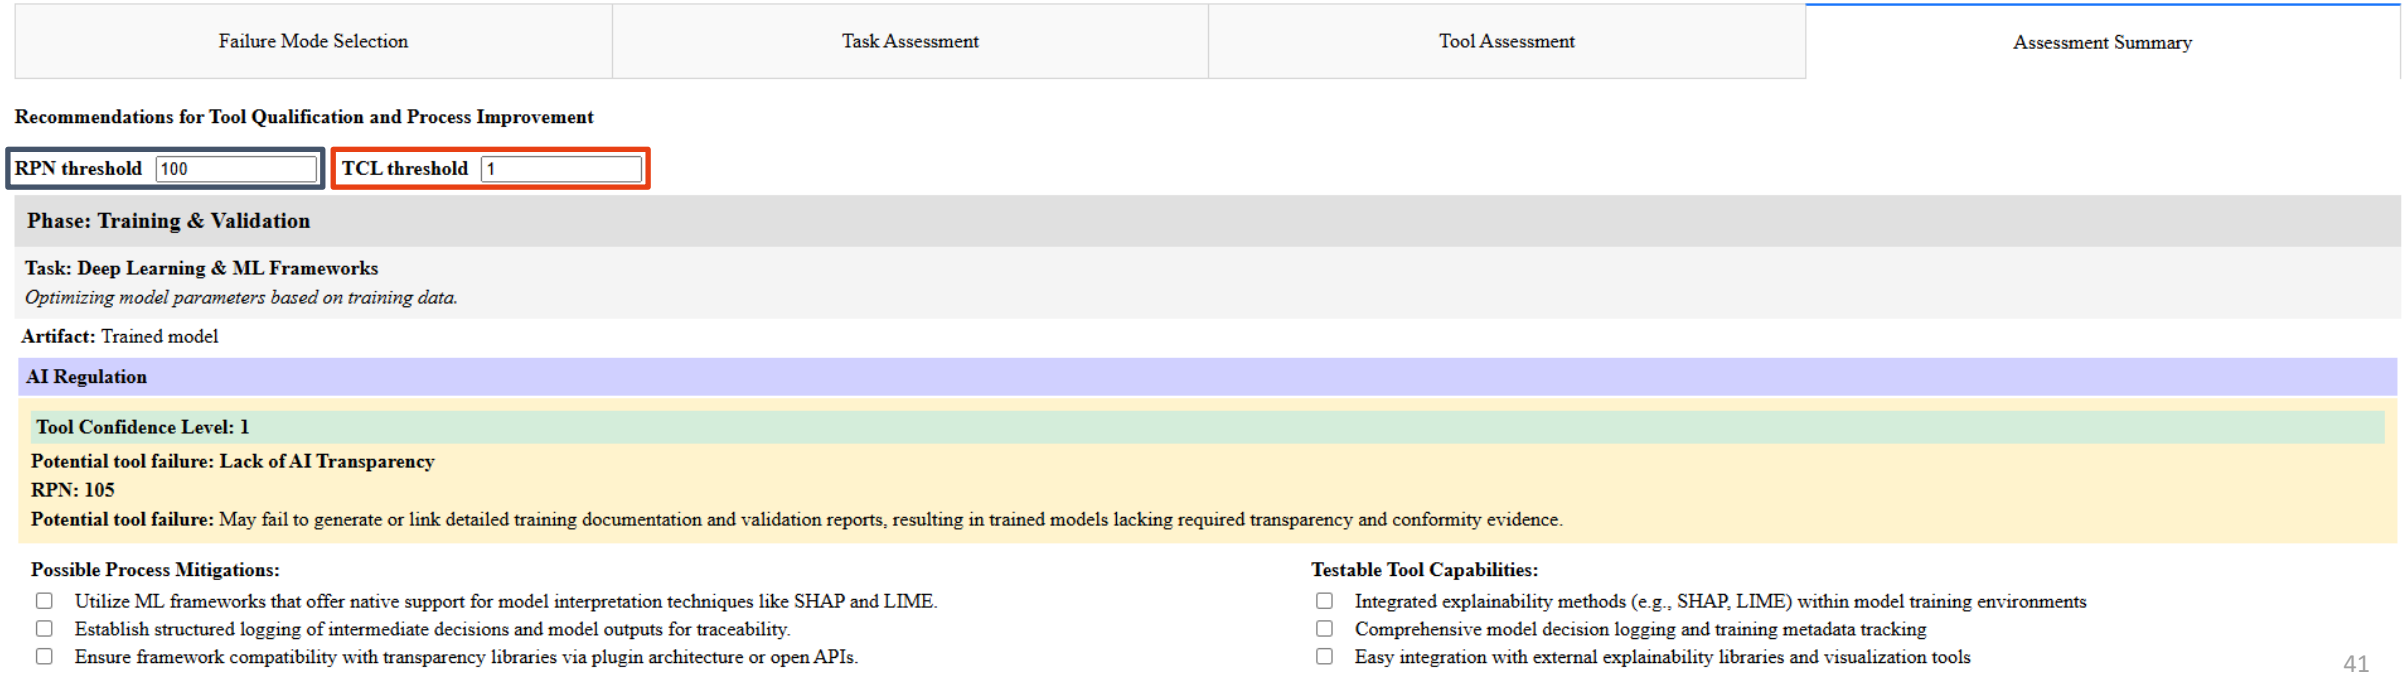

*AssessML: B*ewertung und Handlungsempfehlung

Wozu dienen die Schwellenwerte (thresholds)?

Sämtliche Zustände werden automatisch in das Assessment Summary übernommen, wodurch das Board schnell unübersichtlich werden kann.

Mittels der Schwellenwerte können **kritische Fehlerzustände** oder **unsichere Tools** gezielt gefiltert werden, indem man diese passend einstellt. Durch das Einstellen der Filterung wird die Analyse übersichtlicher.

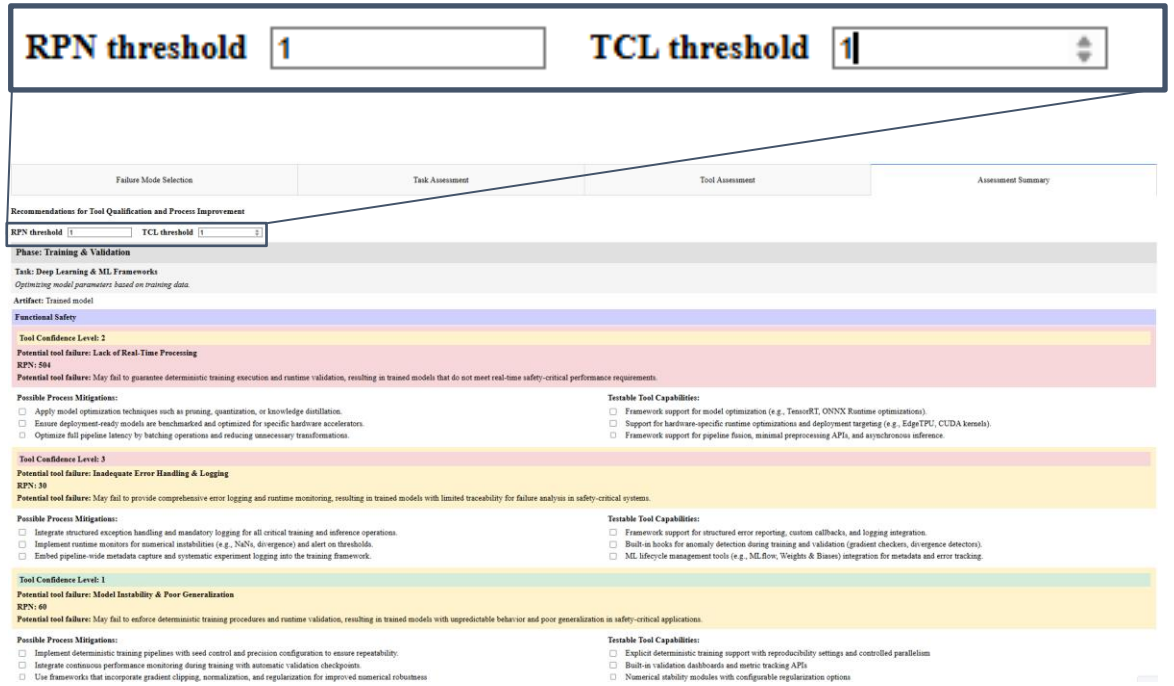

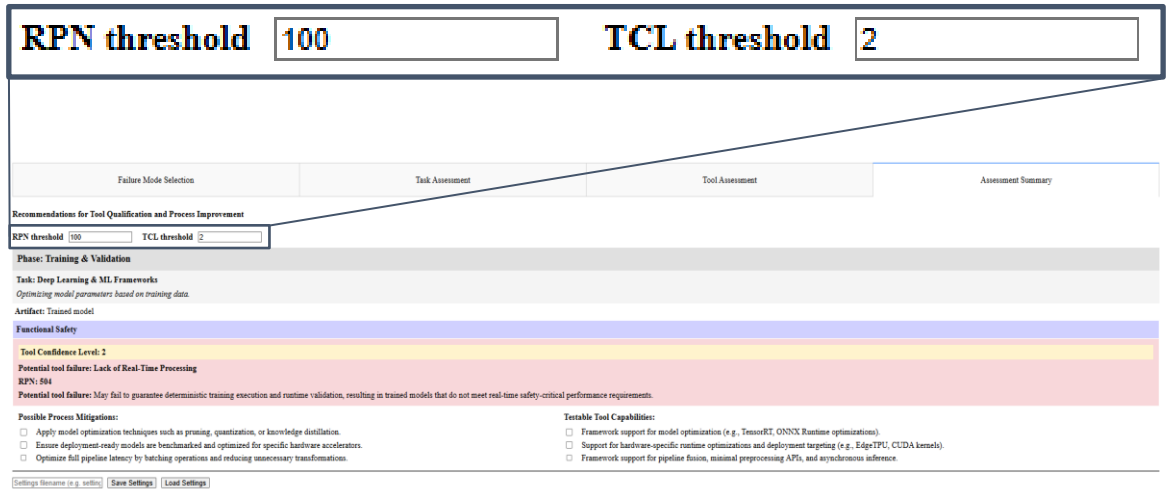

*AssessML: B*ewertung und Handlungsempfehlung

AQI | Automotive Quality Institute

Übersicht über die bestimmte Risikoprioritätskennzahl und das Werkzeugvertrauenslevel

Die unten aufgeführten Select-Kästchen (Checkboxes) dienen dazu, konkrete Tool-Fähigkeiten oder mögliche Prozess-Maßnahmen auszuwählen:

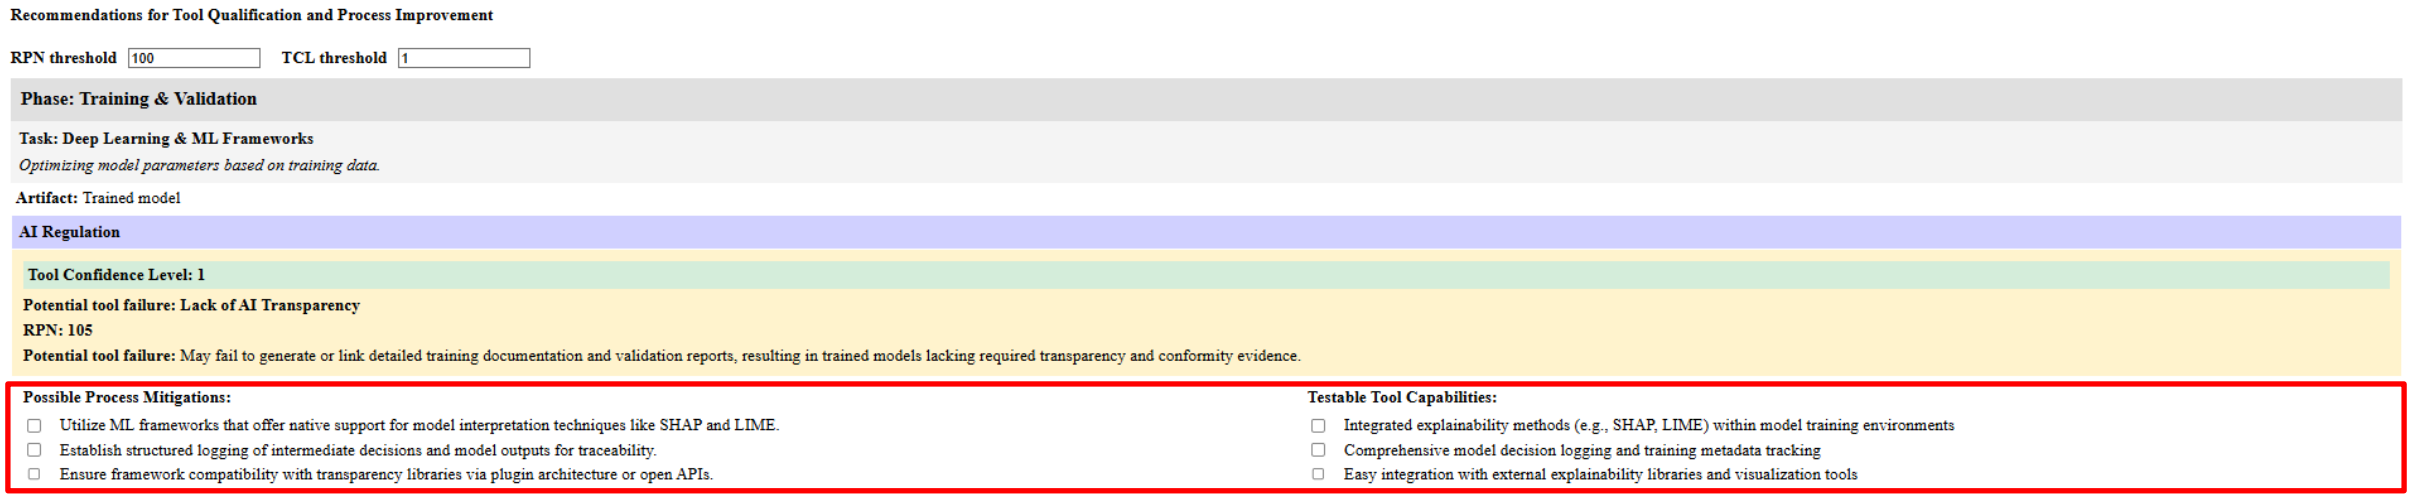

Recommendations for Tool Qualification and Process Improvement

RPN threshold 100 **TCL threshold** 1

Phase: Training & Validation

Task: Deep Learning & ML Frameworks

Optimizing model parameters based on training data.

Artifact: Trained model

AI Regulation

Tool Confidence Level: 1

Potential tool failure: Lack of AI Transparency

RPN: 105

Potential tool failure: May fail to generate or link detailed training documentation and validation reports, resulting in trained models lacking required transparency and conformity evidence.

Possible Process Mitigations:

- ☐ Utilize ML frameworks that offer native support for model interpretation techniques like SHAP and LIME.
- ☐ Establish structured logging of intermediate decisions and model outputs for traceability.
- ☐ Ensure framework compatibility with transparency libraries via plugin architecture or open APIs.

Testable Tool Capabilities:

- ☐ Integrated explainability methods (e.g., SHAP, LIME) within model training environments
- ☐ Comprehensive model decision logging and training metadata tracking
- ☐ Easy integration with external explainability libraries and visualization tools

Possible Process Mitigations (Mögliche Prozess-Maßnahmen):

Hier können Methoden oder Vorgehensweisen ausgewählt werden, die das Risiko eines bestimmten Fehlerzustands verringern sollen.

Testable Tool Capabilities (Überprüfbare Tool-Fähigkeiten):

Hier können konkrete Eigenschaften oder Funktionen von Tools markiert werden, die im Assessment getestet oder überprüft werden sollen.

AssessML: Export und Druck

Automotive Quality Institute

Die Ergebnisse im Assessment Summary können durch drücken des Knopfes „Export PDF“ als PDF exportiert und ausgedruckt werden.

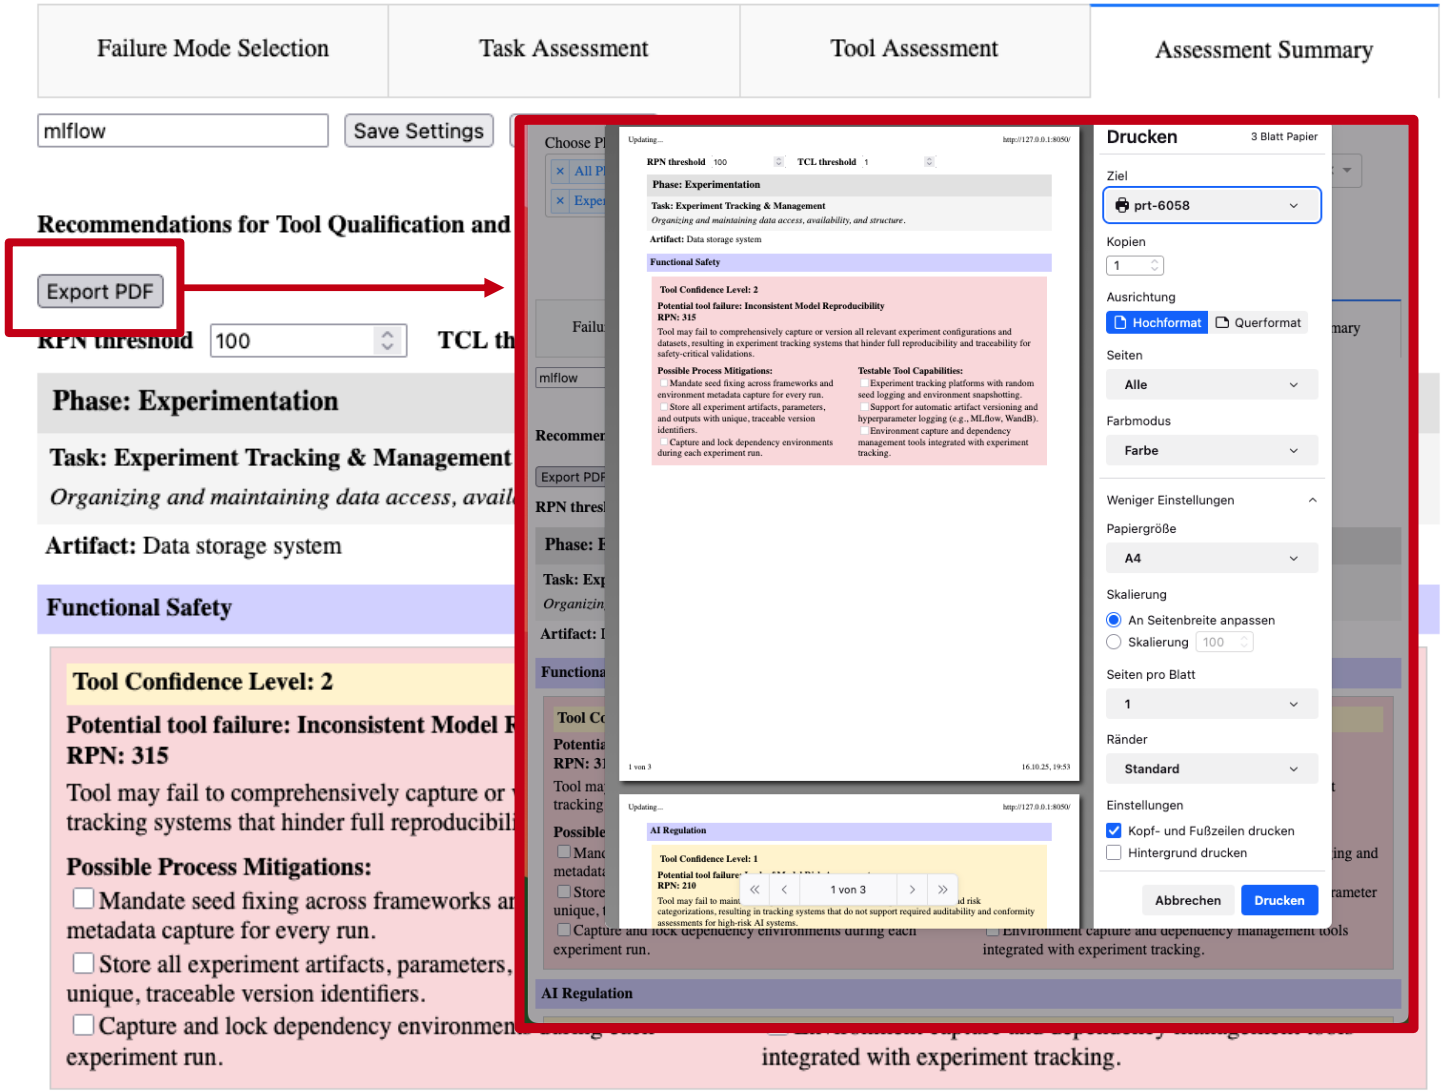

AQI Automotive Quality Institute

Weitere Funktionen der AssessML

AssessML: Speichern und Laden

Warum soll man Speichern und Laden?

Mit der *Save* and *Load Settings* Option können getroffene Einstellungen und bereits durchgeführte Assessment-einstellungen gespeichert und bei Bedarf wieder geladen werden.

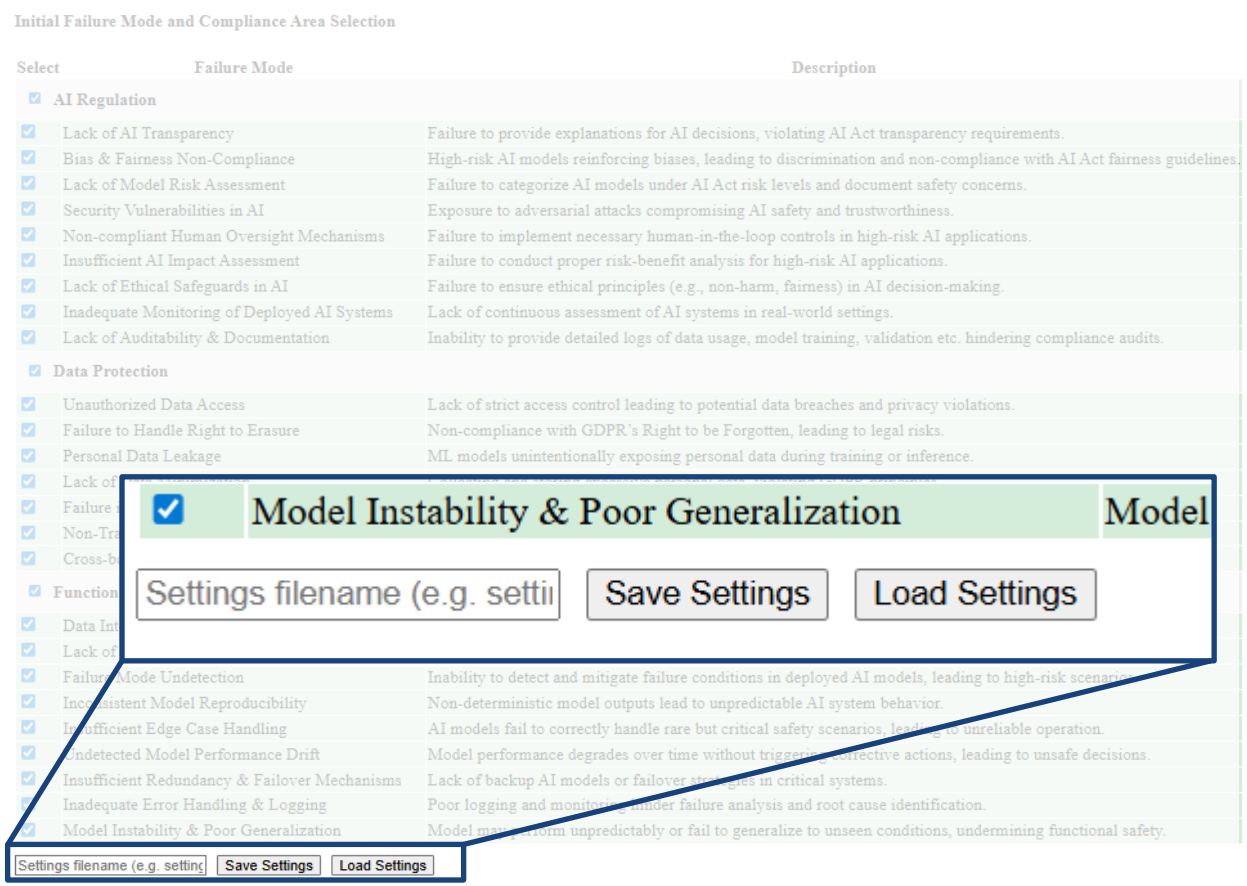

AssessML: Speichern und Laden

Erklärung des Speichervorgangs

Choose Phase(s): × Training & Validation

Choose Task(s): × Deep Learning & ML Frameworks

Choose Tool(s): Select...

Failure Mode Selection | Task Assessment | Tool Assessment | Assessment Summary

Failure Mode and Compliance Area Selection

Select	Failure Mode	Description
☑	**AI Regulation**	
☑	Lack of AI Transparency	Failure to provide explanations for AI decisions, violating AI Act transparency requirements.
☑	Bias & Fairness Non-Compliance	High-risk AI models reinforcing biases, leading to discrimination and non-compliance with AI Act fairness guidelines.
☐	**Data Protection**	
☑	Personal Data Leakage	ML models unintentionally exposing personal data during training or inference.
☐	**Functional Safety**	
☑	Lack of Real-Time Processing	Failure to meet real-time inference requirements in autonomous or safety-critical applications.
☑	Inadequate Error Handling & Logging	Poor logging and monitoring hinder failure analysis and root cause identification.
☑	Model Instability & Poor Generalization	Model may perform unpredictably or fail to generalize to unseen conditions, undermining functional safety.

Setting_1 | Save Settings | Load Settings

Setting_1 | Save Settings | Load Settings

Bereits durchgeführte Such- und Assessmenteinstellungen, können durch „Save Settings“ abgespeichert werden, dazu:

1. Select-Kästchen auswählen
2. Namen vergeben
3. Mit Save Settings speichern

AssessML: Speichern und Laden

Erklärung des Speichervorgangs

Gespeicherte Settings, werden unten aufgelistet. Um gespeicherte Settings abzurufen:

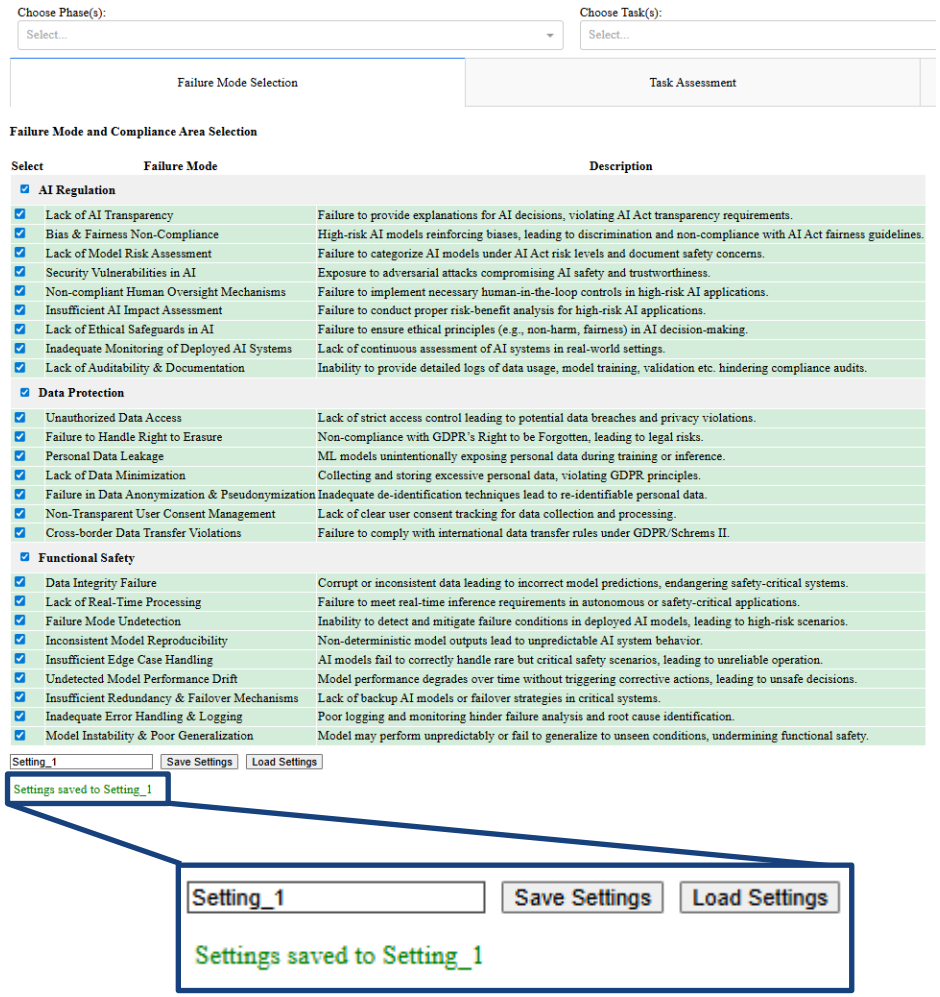

1. Setting-Namen eingeben
2. Load Settings klicken
3. Dashboard lädt Konfiguration

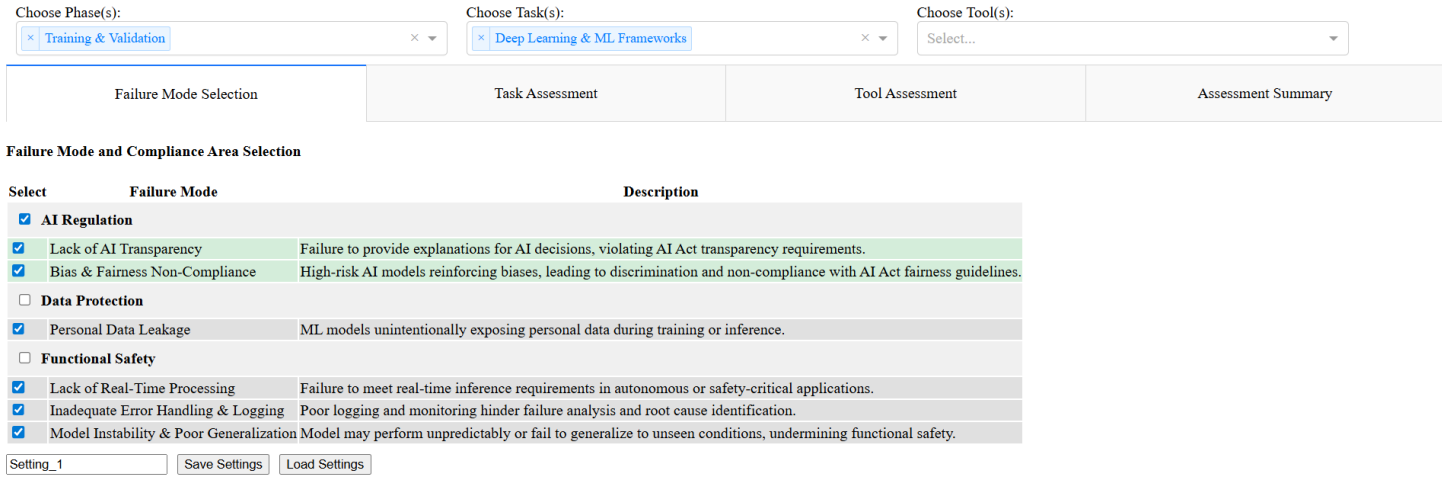

AssessML: Speichern und Laden

Hinweis

Gespeicherte Settings übernehmen sowohl die ausgewählten Fehlerzustände, als auch bereits durchgeführte Assessments und das Summary.

Failure Mode Overview

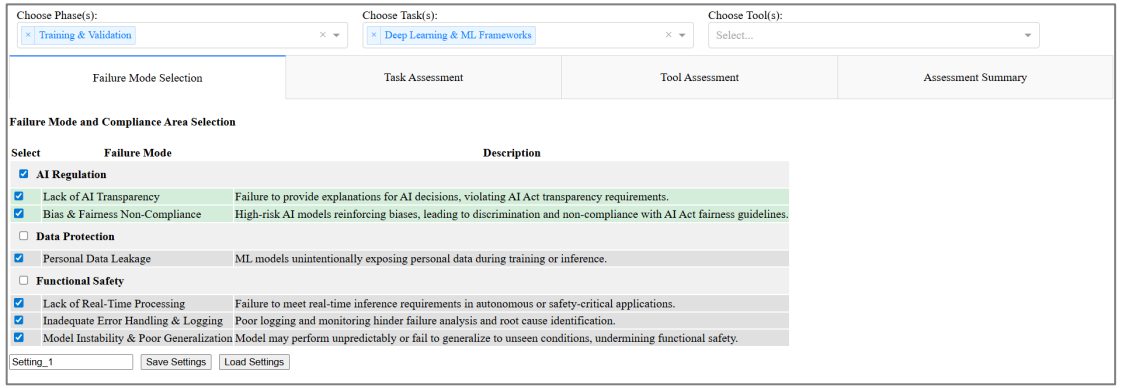

Task Assessment

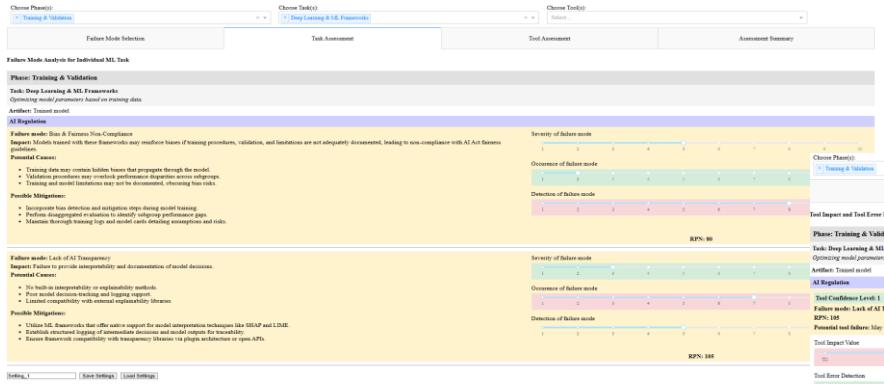

Tools Assessment

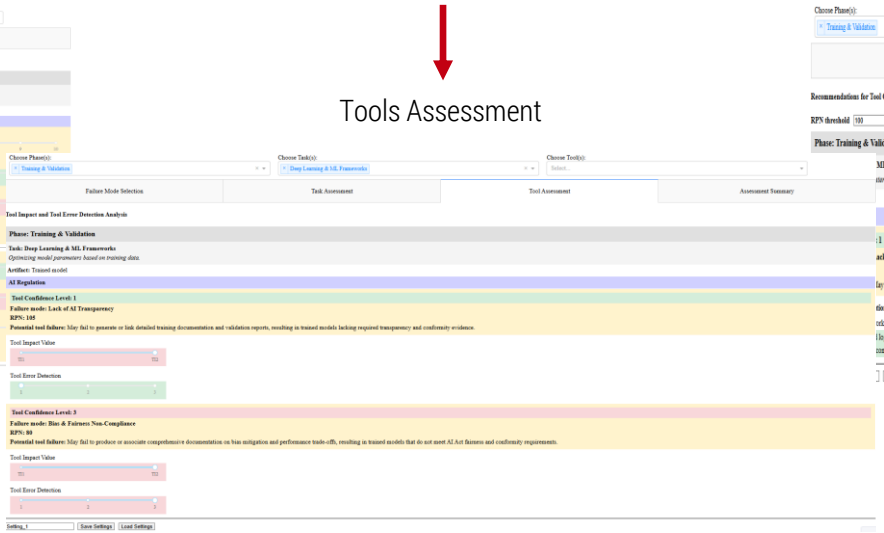

Assessment Summary