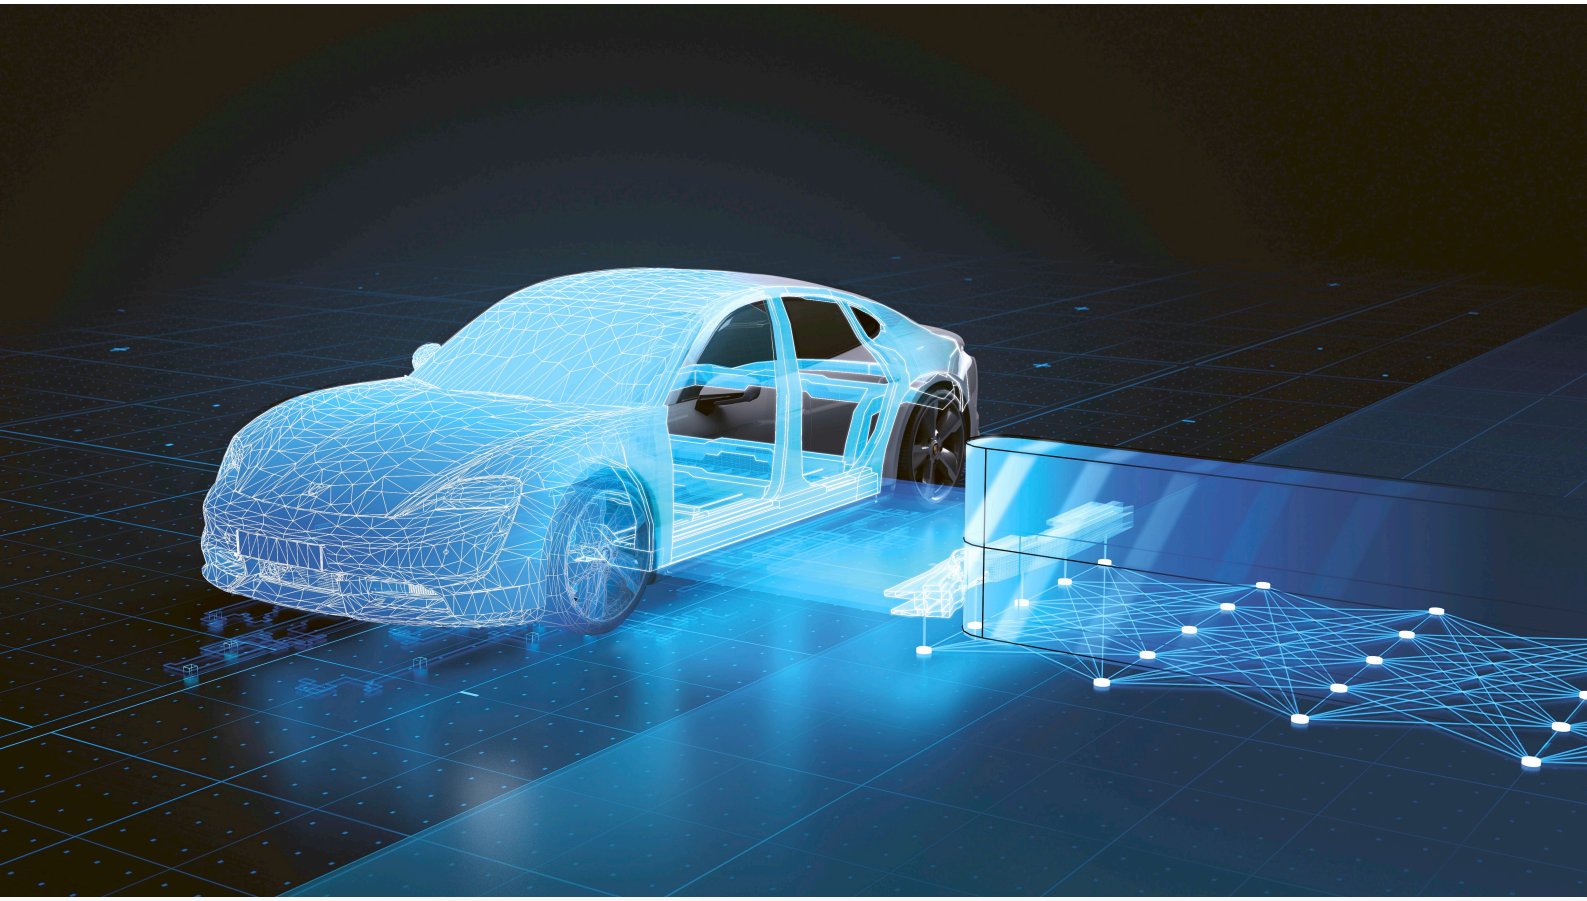


Doppelt optimiert: Reinforcement-Learning-Agent & Neuronales Netz

06/05/2022 Porsche Engineering hat zwei Methoden der Künstlichen Intelligenz kombiniert, um einen Seitenschweller effizient zu optimieren: Ein Reinforcement-Learning-Agent findet die beste Variante des Bauteils – unterstützt von einem Neuronalen Netz, das die einzelnen Optimierungsschleifen stark beschleunigt.

Sie sind unscheinbare Lebensretter: Die beiden Seitenschweller schutzen die Insassen, falls ein Fahrzeug von der Straße abkommt und beispielsweise seitlich gegen einen Baum prallt. In rein-elektrischen Fahrzeugen haben sie eine weitere wichtige Aufgabe: den Schutz der Hochvoltbatterie, die zwischen linkem und rechtem Seitenschweller untergebracht ist und bei einem Unfall nicht ubermaßig deformiert werden darf. Entsprechend viel Arbeit investieren Entwickler in die Optimierung des Crashverhaltens der Komponente.

Vom optimalen Crashverhalten eines Seitenschwellers haben sie dabei eine klare Vorstellung: Die Verformung (Intrusion) sollte einen moglichst stetigen Verlauf ohne allzu große lokale Schwankungen aufweisen. Dieser Zusammenhang zwischen außerer Kraft beim Crash und Seitenschweller-Intrusion

lasst sich durch eine Idealkurve darstellen. Ihr sollte das tatsachliche Verhalten der Komponente so nahe wie moglich kommen.

Wahrend der Entwicklung kommen fur solche Optimierungen meist Simulationen zum Einsatz, denn Prototypen fur Crashtests sind teuer. Bei der weitverbreiteten Finite-Elemente-Methode (FEM) zerlegt man das reale Fahrzeug oder Bauteil fur Crashsimulationen meist in kleine Vierecke („Elemente"), deren Ecken „Knoten" genannt werden. Das Verhalten bei einem Aufprall lasst sich durch die Reaktion der einzelnen Elemente auf außere Krafte berechnen – umso praziser, je mehr Elemente und Knoten das FEM-Modell enthalt. „Eine hohere Genauigkeit schlagt sich allerdings auch in einem großeren Rechenaufwand nieder", erklart Johannes Pfahler, Berechnungsingenieur bei Porsche Engineering. „Fur FEM-Simulationen sind Hochleistungscomputer erforderlich, und bei einem Gesamtfahrzeugmodell kann eine einzige Crash-Berechnung einen Tag oder langer dauern."

Das gilt auch fur die Crash-Simulation des Seitenschwellers in einem rein-elektrischen Fahrzeug. Das Bauteil stammte aus einem Vorentwicklungsprojekt der Porsche AG. Um die Komponente zu optimieren, konnten die Ingenieure von Porsche Engineering 14 Wandstarken variieren und das Crashverhalten jeder Variante mit dem idealen Verlauf vergleichen. Hatten die Berechnungsingenieure dafur ein FEM-Gesamtfahrzeugmodell mit 9,6 Millionen Elementen und 6,6 Millionen Knoten verwendet, ware ein Computer mit 128 Mikroprozessorkernen (CPUs) fast 20 Stunden beschaftigt – nur um das Crashverhalten einer einzigen Schweller-Variante zu berechnen. Ein vereinfachtes FEM-Teilmodell aus Seitenschweller, Unterboden und Batteriekonstruktion (1,6 Millionen Elemente und 1,9 Millionen Knoten) hatte einen Computer mit 64 CPUs immer noch fur etwas mehr als vier Stunden pro Simulation ausgelastet. Gefragt war darum eine effizientere Methode, um Hunderte oder Tausende von Schweller-Varianten mit unterschiedlichen Wandstarken auf ihr individuelles Crashverhalten zu untersuchen.

Ein Fall fur den RL-Agenten

Hier kamen Dr. Joachim Schaper, Leiter Fachdisziplin KI und Big Data bei Porsche Engineering, und die anderen KI-Experten des Unternehmens ins Spiel. Ihre Idee: Durch die Kombination der beiden KI-Verfahren Reinforcement Learning (RL) und Neuronale Netze (NN) sollte sich die optimale Schweller-Variante mit vertretbarem Rechenaufwand finden lassen. Beim Reinforcement Learning interagiert ein Algorithmus („Agent" genannt) mit seiner Umgebung und lernt durch Feedback permanent hinzu – indem er fur Aktionen, die zu einem guten Ergebnis fuhren, mit Bonuspunkten belohnt und bei Misserfolgen mit Abzugen bestraft wird. Sein Ziel war es in diesem Fall, im Lauf der Zeit die Variante mit der hochstmoglichen Punktzahl zu finden. Dazu sollte sich der RL-Agent durch Variation der 14 Wandstarken immer naher an das ideale Crashverhalten des Seitenschwellers herantasten.

Wie gut ihm das im Einzelfall gelungen ist, ließe sich prinzipiell durch eine FEM-basierte Simulation des Crashverhaltens jeder vorgeschlagenen Variante ermitteln – ware der Rechen- und Zeitaufwand dafur nicht viel zu hoch. Diesen reduziert das zweite eingesetzte KI-Verfahren deutlich: Das Feedback fur den RL-Agenten liefert keine Simulation, sondern ein Neuronales Netz. „Wir haben es zuvor mithilfe von

Simulationsdaten darauf trainiert, aus den Wandstarken als Eingabe das Crashverhalten des Seitenschwellers als Ausgabe vorherzusagen", erklart Schaper. „Das dauert fur jede Seitenschweller-Variante nur Sekunden, im Gegensatz zu Stunden bei einer klassischen Simulation. Dennoch mussen wir keine Abstriche bei der Genauigkeit des Feedbacks fur den RL-Agenten machen."

Mit dieser Kombination der beiden KI-Verfahren konnte die Schweller-Optimierung starten. Die 14 Wandstarken fur die erste Schleife wurden nicht zufallig gewahlt, sondern stammten von Dr. Philipp Kellner, Fachreferent Karosserie Vorentwicklung bei der Porsche AG. „Als Experte wusste er aus langjahriger Erfahrung, wie eine gute Kombination aussehen konnte", so Pfahler. „Der Ausgangspunkt fur den Reinforcement-Learning- Agenten war also schon recht gut." Das Neuronale Netz verglich daraufhin das Crashverhalten dieser speziellen Seitenschweller-Variante mit dem Idealverlauf und speiste die Abweichung als Feedback in den Agenten ein, der wiederum die nachste Kombination aus 14 Wandstarken an das Neuronale Netz lieferte. Dieses Spiel wiederholte sich mehrere Tausend Mal, und mit jeder Iteration kam das KI-Team aus RL-Agent und Neuronalem Netz seinem Ziel ein Stuck naher: den optimalen Seitenschweller zu finden.

Hier zeigte sich auch die Starke des Reinforcement Learning. „Wir haben lange daruber nachgedacht, welche KI-Methode fur diese Aufgabe am besten funktionieren konnte", berichtet Schaper. „Der Vorteil des Reinforcement Learning: Der Agent merkt sich die Historie seiner Versuche. Er weiß also, was bisher gut funktioniert hat und was nicht – eine wichtige Voraussetzung, um eine gute Strategie fur die effiziente Optimierung des Seitenschwellers zu entwickeln." Sein Vertrauen in den RL-Ansatz erwies sich als gerechtfertigt: Nach mehreren Tausend Iterationen lieferten die beiden KI-Methoden eine Seitenschweller-Variante, die eine ausreichend gute Ubereinstimmung mit der Idealkurve aufwies. Das Ziel war erreicht – in einem Bruchteil der Zeit, die ein konventionelles Vorgehen erfordert hatte.

Lernen aus Erfahrung

Insgesamt benotigten die Entwickler etwa 23 Tage Rechenzeit, um ans Ziel zu kommen. Der bei Weitem große Aufwand steckte in den 548 Crash-Simulationen, mit denen das Neuronale Netz trainiert beziehungsweise validiert wurde. Sie beruhten auf einem weiter vereinfachten FEM-Modell des Seitenschwellers, das aus nur noch rund 132.000 Elementen und 129.000 Knoten besteht. Pro Variante ließ sich jeder Crash damit in einer Stunde berechnen – auf einer normalen Workstation mit vier CPUs. „Hatten wir den optimalen Seitenschweller mithilfe klassischer Simulationen unter 548 Varianten gesucht, ware ein Hochleistungscomputer 96 Tage beschaftigt gewesen", so Pfahler. „Außerdem hatten wir moglicherweise die optimalen Wandstarken verfehlt, wenn wir im falschen Bereich des Parameterraumes nach ihnen gesucht hatten – was weitere aufwendige Simulationen nach sich gezogen hatte."

Das Optimierungsprojekt startete Ende 2020 mit einer Analyse des aktuellen Stands der Technik. Bereits im ersten Quartal 2021 war der Trainings- und Validierungsdatensatz fur das Neuronale Netz verfugbar, das im zweiten Quartal trainiert wurde. Parallel dazu entwickelten die KI-Experten von Porsche Engineering den RL-Agenten und ließen ihn schließlich die Seitenschweller-Optimierung

durchfuhren. Derzeit arbeiten sie daran, das erfolgreiche Gespann aus den beiden KI-Verfahren fur weitere Optimierungen einzusetzen. „Wir wollen zum Beispiel herausfinden, ob der vortrainierte RL-Agent fur einen anderen Crash oder ein anderes Bauteil eine vollig neue Strategie entwickeln muss oder ob er die alte wiederverwenden kann", sagt Pfahler.

Effizientere Umsetzung als Ziel

In Zukunft soll der RL-Agent eingesetzt werden, um Optimierungsmoglichkeiten bei Front- und Heckcrashs zu finden. Außerdem wollen Schaper, Pfahler und ihre Kollegen untersuchen, wie sich das Verfahren noch effizienter umsetzen lasst. „Wir haben das Neuronale Netz fur die Seitenschweller-Optimierung mit 300 Datensatzen trainiert, wodurch es sehr prazise Ergebnisse geliefert hat", berichtet Schaper. „Das sind allerdings ungewohnlich viele Daten – in der Regel stehen nur zehn bis 20 Simulationsergebnisse fur das Training zur Verfugung." Nun geht es um Fragen wie: Kann das Neuronale Netz auch mit deutlich weniger Trainingsdaten noch genaue Aussagen uber das Crashverhalten liefern? Wo ist der beste Kompromiss aus Trainingsaufwand und Prazision? Welche Fehlerrate des Neuronalen Netzes kann man tolerieren? „Sicher ist bereits jetzt, dass wir KI fur die Optimierung von Komponenten nutzen konnen", resumiert Pfahler. „Nun geht es darum, das Verfahren zu verbessern und in die Serienentwicklung zu integrieren."

Dass die Kombination aus Reinforcement Learning und Neuronalen Netzen wichtige Impulse geben kann, haben die KI-Experten von Porsche Engineering bereits im Projekt PERL gelernt: Mit RL war es ihnen gelungen, automatisch eine optimale Applikationsstrategie fur Motoren zu finden, die sich universell fur Modelle mit unterschiedlichen Bauformen und Hubraumen sowie mit verschiedenen Aufladesystemen einsetzen lasst. „Zwischen PERL und dem aktuellen Projekt gibt es viele Parallelen: In beiden Fallen geht es zum Beispiel darum, in einem großen Suchraum die optimale Konstellation zu finden", erklart Schaper. „Und es hat sich wieder gezeigt: Reinforcement Learning ist im KI-Bereich die Konigsklasse fur Optimierungsaufgaben."

Zusammengefasst

Durch die Kombination der beiden KI-Methoden Reinforcement Learning und Neuronales Netz konnte Porsche Engineering einen Seitenschweller ohne den Einsatz von Hochleistungsrechnern sehr effizient optimieren. Nun wird untersucht, wie sich das Verfahren selbst weiter verbessern lasst und in welchen anderen Bereichen es eingesetzt werden konnte.

Info

Text erstmals erschienen im Porsche Engineering Magazin, Ausgabe 1/2022.

Autor: Christian Buck

Illustrationen: Jurij Chrubasik

Copyright: Alle in diesem Artikel veröffentlichten Bilder, Videos und Audio-Dateien unterliegen dem Copyright. Eine Reproduktion oder Wiedergabe des Ganzen oder von Teilen ist ohne die schriftliche Genehmigung der Dr. Ing. h.c. F. Porsche AG nicht gestattet. Bitte kontaktieren Sie newsroom@porsche.com für weitere Informationen.

MEDIA ENQUIRIES



Inga Konen

Head of Communications Porsche Schweiz AG
+41 (0) 41 / 487 914 3
inga.konen@porsche.ch

Link Collection

Link to this article
https://newsroom.porsche.com/de_CH/2022/innovation/porsche-engineering-doppelt-optimiert-reinforcement-learning-agent-neuronales-netz-28252.html

External Links
https://www.porscheengineering.com/peg/en/