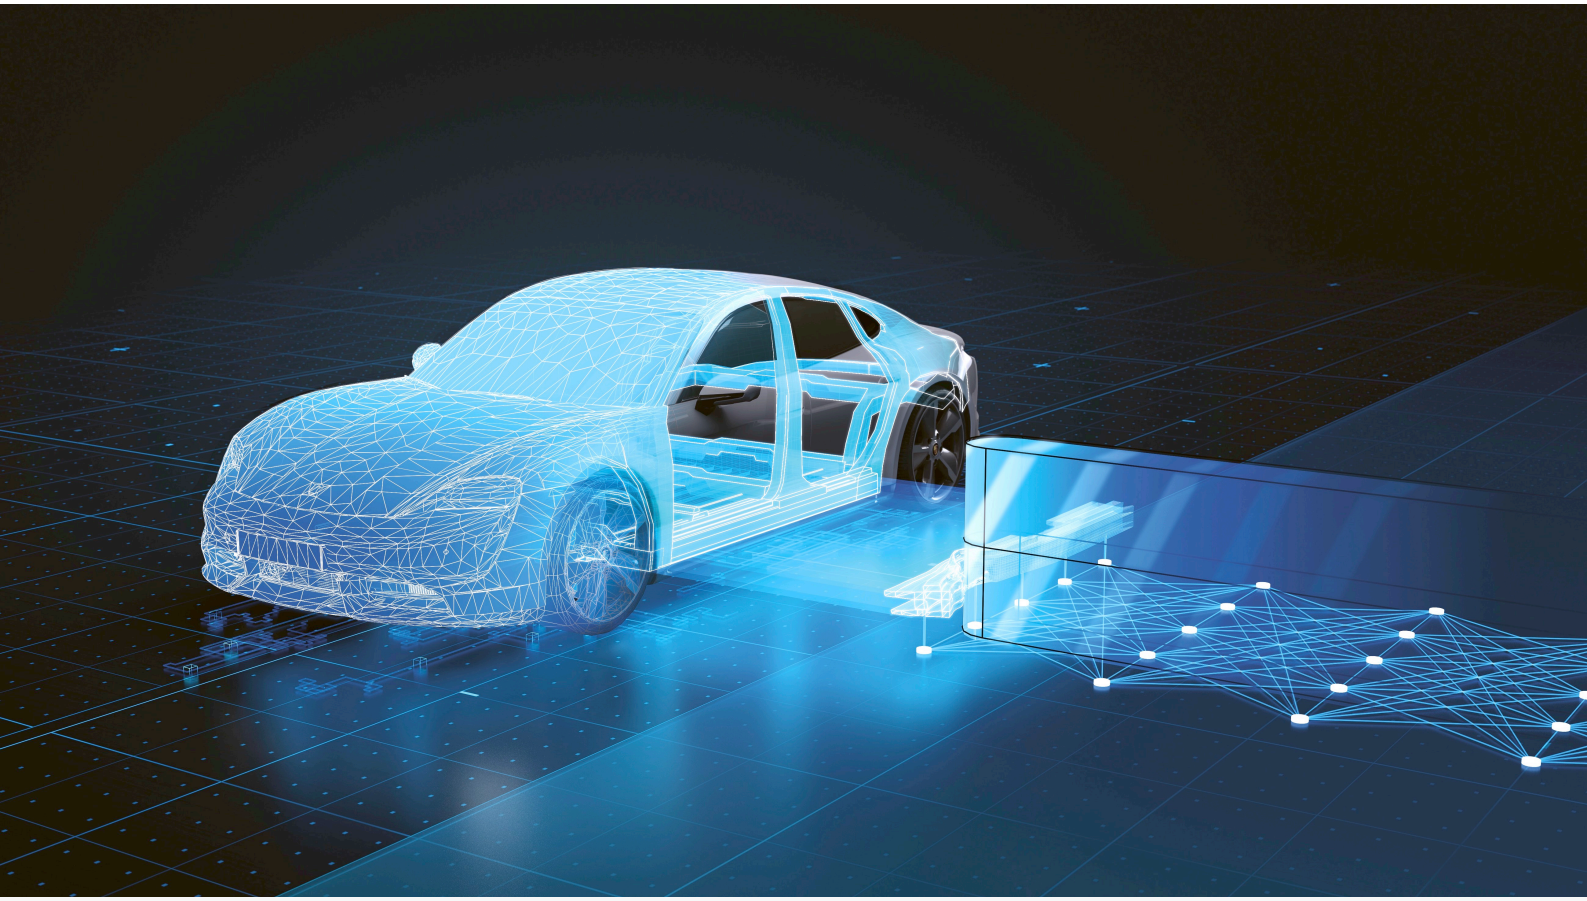


Doppelt optimiert: Reinforcement-Learning-Agent & Neuronales Netz

Dieser Artikel gibt den Stand zum Zeitpunkt seiner Veröffentlichung wieder. Der Inhalt kann inzwischen veraltet sein.

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 schu□tzen 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 u□berma□ßig 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 mo☒glichst stetigen Verlauf ohne allzu große lokale Schwankungen aufweisen. Dieser Zusammenhang zwischen a☒ußerer Kraft beim Crash und Seitenschweller-Intrusion la☒sst sich durch eine Idealkurve darstellen. Ihr sollte das tatsa☒chliche Verhalten der Komponente so nahe wie mo☒glich kommen.

Wa☒hrend der Entwicklung kommen fu☒r solche Optimierungen meist Simulationen zum Einsatz, denn Prototypen fu☒r Crashtests sind teuer. Bei der weitverbreiteten Finite-Elemente-Methode (FEM) zerlegt man das reale Fahrzeug oder Bauteil fu☒r Crashsimulationen meist in kleine Vierecke („Elemente"), deren Ecken „Knoten" genannt werden. Das Verhalten bei einem Aufprall la☒sst sich durch die Reaktion der einzelnen Elemente auf a☒ußere Kra☒fte berechnen – umso pra☒ziser, je mehr Elemente und Knoten das FEM-Modell entha☒lt. „Eine ho☒here Genauigkeit schla☒gt sich allerdings auch in einem gro☒ßeren Rechenaufwand nieder", erkla☒rt Johannes Pfahler, Berechnungsingenieur bei Porsche Engineering. „Fu☒r FEM-Simulationen sind Hochleistungscomputer erforderlich, und bei einem Gesamtfahrzeugmodell kann eine einzige Crash-Berechnung einen Tag oder la☒nger dauern."

Das gilt auch fu☒r 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 Wandsta☒rken variieren und das Crashverhalten jeder Variante mit dem idealen Verlauf vergleichen. Ha☒tten die Berechnungsingenieure dafu☒r ein FEM-Gesamtfahrzeugmodell mit 9,6 Millionen Elementen und 6,6 Millionen Knoten verwendet, wa☒re ein Computer mit 128 Mikroprozessorkernen (CPUs) fast 20 Stunden bescha☒ftigt – 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) ha☒tte einen Computer mit 64 CPUs immer noch fu☒r etwas mehr als vier Stunden pro Simulation ausgelastet. Gefragt war darum eine effizientere Methode, um Hunderte oder Tausende von Schweller-Varianten mit unterschiedlichen Wandsta☒rken auf ihr individuelles Crashverhalten zu untersuchen.

Ein Fall fu☒r 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 fu☒r Aktionen, die zu einem guten Ergebnis fu☒hren, mit Bonuspunkten belohnt und bei Misserfolgen mit Abzu☒gen bestraft wird. Sein Ziel war es in diesem Fall, im Lauf der Zeit die Variante mit der ho☒chstmo☒glichen Punktzahl zu finden. Dazu sollte sich der RL-Agent durch Variation der 14 Wandsta☒rken immer na☒her 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 – wa✕re der Rechen- und Zeitaufwand dafu✕r nicht viel zu hoch. Diesen reduziert das zweite eingesetzte KI-Verfahren deutlich: Das Feedback fu✕r den RL-Agenten liefert keine Simulation, sondern ein Neuronales Netz. „Wir haben es zuvor mithilfe von Simulationsdaten darauf trainiert, aus den Wandsta✕rken als Eingabe das Crashverhalten des Seitenschwellers als Ausgabe vorherzusagen", erkla✕rt Schaper. „Das dauert fu✕r jede Seitenschweller-Variante nur Sekunden, im Gegensatz zu Stunden bei einer klassischen Simulation. Dennoch mu✕ssen wir keine Abstriche bei der Genauigkeit des Feedbacks fu✕r den RL-Agenten machen."

Mit dieser Kombination der beiden KI-Verfahren konnte die Schweller-Optimierung starten. Die 14 Wandsta✕rken fu✕r die erste Schleife wurden nicht zufa✕llig gewa✕hlt, sondern stammten von Dr. Philipp Kellner, Fachreferent Karosserie Vorentwicklung bei der Porsche AG. „Als Experte wusste er aus langja✕hriger Erfahrung, wie eine gute Kombination aussehen ko✕nnte", so Pfahler. „Der Ausgangspunkt fu✕r 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 na✕chste Kombination aus 14 Wandsta✕rken 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 Stu✕ck na✕her: den optimalen Seitenschweller zu finden.

Hier zeigte sich auch die Sta✕rke des Reinforcement Learning. „Wir haben lange daru✕ber nachgedacht, welche KI-Methode fu✕r diese Aufgabe am besten funktionieren ko✕nnte", 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 fu✕r 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 U✕bereinstimmung mit der Idealkurve aufwies. Das Ziel war erreicht – in einem Bruchteil der Zeit, die ein konventionelles Vorgehen erfordert ha✕tte.

Lernen aus Erfahrung

Insgesamt beno✕tigten die Entwickler etwa 23 Tage Rechenzeit, um ans Ziel zu kommen. Der bei Weitem gro✕ßte 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. „Ha✕tten wir den optimalen Seitenschweller mithilfe klassischer Simulationen unter 548 Varianten gesucht, wa✕re ein Hochleistungscomputer 96 Tage bescha✕ftigt gewesen", so Pfahler. „Außerdem ha✕tten wir mo✕glicherweise die optimalen Wandsta✕rken verfehlt, wenn wir im falschen Bereich des Parameterraumes nach ihnen gesucht ha✕tten – was weitere aufwendige Simulationen nach sich gezogen ha✕tte."

Das Optimierungsprojekt startete Ende 2020 mit einer Analyse des aktuellen Stands der Technik. Bereits im ersten Quartal 2021 war der Trainings- und Validierungsdatensatz fu☒r das Neuronale Netz verfu☒gbar, 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 durchfu☒hren. Derzeit arbeiten sie daran, das erfolgreiche Gespann aus den beiden KI-Verfahren fu☒r weitere Optimierungen einzusetzen. „Wir wollen zum Beispiel herausfinden, ob der vortrainierte RL-Agent fu☒r einen anderen Crash oder ein anderes Bauteil eine vo☒llig 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 Optimierungsmo☒glichkeiten bei Front- und Heckcrashs zu finden. Außerdem wollen Schaper, Pfahler und ihre Kollegen untersuchen, wie sich das Verfahren noch effizienter umsetzen la☒sst. „Wir haben das Neuronale Netz fu☒r die Seitenschweller-Optimierung mit 300 Datensa☒tzen trainiert, wodurch es sehr pra☒zise Ergebnisse geliefert hat“, berichtet Schaper. „Das sind allerdings ungewo☒hnlich viele Daten – in der Regel stehen nur zehn bis 20 Simulationsergebnisse fu☒r das Training zur Verfu☒gung.“ Nun geht es um Fragen wie: Kann das Neuronale Netz auch mit deutlich weniger Trainingsdaten noch genaue Aussagen u☒ber das Crashverhalten liefern? Wo ist der beste Kompromiss aus Trainingsaufwand und Pra☒zision? Welche Fehlerrate des Neuronalen Netzes kann man tolerieren? „Sicher ist bereits jetzt, dass wir KI fu☒r die Optimierung von Komponenten nutzen ko☒nnen“, resu☒miert 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 fu☒r Motoren zu finden, die sich universell fu☒r Modelle mit unterschiedlichen Bauformen und Hubra☒umen sowie mit verschiedenen Aufladesystemen einsetzen la☒sst. „Zwischen PERL und dem aktuellen Projekt gibt es viele Parallelen: In beiden Fa☒llen geht es zum Beispiel darum, in einem großen Suchraum die optimale Konstellation zu finden“, erkla☒rt Schaper. „Und es hat sich wieder gezeigt: Reinforcement Learning ist im KI-Bereich die Ko☒nigsklasse fu☒r 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 la☒sst und in welchen anderen Bereichen es eingesetzt werden ko☒nnte.

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



Sandro Kälin

Head of Communications Porsche Schweiz AG
+41 41 487 91 16
sandro.kaelin@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/