

Mit Versicherungsdaten zur besseren Tiergesundheit

—
Dr. Christian Debes

—
Johannes Wowra

Spryfox arbeitet seit vier Jahren eng mit der US-amerikanischen Tierkrankenversicherung Fetch zusammen. Fetch hat Daten aus 18 Jahren von mehr als 800 000 versicherten Hunden gesammelt. Mit diesen umfangreichen Daten konnte ein Vorhersagemodell entwickelt werden, das individuelle Gesundheitsprognosen für Hunde erstellt. Es berücksichtigt dabei Faktoren wie Rasse, Krankheitsgeschichte, Wohnort und weitere externe Informationen, um die Wahrscheinlichkeit von 48 verschiedenen Krankheiten vorherzusagen.

Dieses KI-Modell wird in vielen Bereichen genutzt, etwa in neuen digitalen Angeboten für Fetch-Kunden und in Tools für den Vertrieb. In diesem Artikel schauen wir uns an, wie das KI-Modell entwickelt wurde und welchen Einfluss es auf die digitale Transformation bei Fetch hat. Ein besonderes Augenmerk liegt dabei auf der «Erklärbaren KI», die geholfen hat, ein zuverlässiges und vertrauenswürdiges KI-Modell zu schaffen.

Motivation

Der globale Markt für Tierversicherungen hatte 2023 ein Volumen von 10,1 Milliarden Dollar und soll bis 2033 auf 38,3 Milliarden Dollar anwachsen (Allied Market Research, 2024). Dieses Wachstum resultiert nicht nur aus der steigenden Anzahl von Tierhaltern (88 Millionen Haushalte in Europa, 84 Millionen in den USA), sondern auch aus der veränderten Rolle von Haustieren in den letzten Jahrzehnten. So zeigen

Studien, dass Haustiere zunehmend als Familienmitglieder angesehen werden (Cohen, 2002). Diese Veränderung und die damit stärkere emotionale Bindung zu Haustieren erhöhen die Nachfrage nach Produkten wie Tierkrankenversicherungen und Wellness-Produkten.

Für Tierkrankenversicherungen bietet sich hier eine Chance, neue digitale Angebote zu entwickeln, die über die reine Risikoabsicherung hinausgehen. Ein Beispiel ist der Einsatz von künstlicher Intelligenz, um basierend auf Versicherungsdaten Krankheiten vorherzusagen. Solche Technologien ermöglichen innovative personalisierte Anwendungen, die einen zusätzlichen Mehrwert bieten, wie zum Beispiel eine stärkere Kundenbindung, bessere Akquise und neue Einnahmequellen ausserhalb des bestehenden Kundenstamms.

In diesem Artikel möchten wir unsere Zusammenarbeit mit der amerikanischen Tierversicherung Fetch vorstellen und zeigen, wie wir durch innovative KI-Anwendungen einen Mehrwert aus vorhandenen Versicherungsdaten schaffen konnten.

Die Datenlage

Fetch ist ein führender Anbieter von Tierversicherungen in den USA und Kanada. Seit der Gründung im Jahr 2006 ist die Datenbasis kontinuierlich gewachsen. Im Jahr 2024 umfasst sie Daten von 800 000 versicherten Hunden und über 2,4 Millionen Versicherungsfällen. Fetch hat frühzeitig in gute Datenpflege und Qualitätssicherung investiert, was es heute ermöglicht, diese Daten auch für andere Zwecke ausserhalb des Kerngeschäfts zu nutzen.

Um zuverlässige Vorhersagen für zukünftige Krankheiten zu treffen, war es wichtig, alle verfügbaren Fetch-internen Daten zu Hunden und Versicherungsfällen zu berücksichtigen und sie mit externen Informationen zu ergänzen. Das Vorhersagemodell wurde daher mit den folgenden Datentypen gefüttert:

Vorherige Krankheits- und Versicherungsgeschichte

Frühere Krankheiten und Versicherungsfälle sind starke Indikatoren für zukünftige Erkrankungen. Das Modell berücksichtigt Informationen über die Existenz früherer Krankheiten, die Häufigkeit der Versicherungsmeldungen und die Zeit seit der letzten Erkrankung. Diese Daten werden entsprechend codiert, um dem KI-Modell zu ermöglichen, Zusammenhänge zwischen Vorerkrankungen und zukünftigen Krankheiten zu lernen.

Der Datensatz von Fetch enthält über 1000 verschiedene Krankheits-Codes, die zur besseren Modellierung in Krankheitsgruppen zusammengefasst wurden. Beispiele für solche Krankheitsgruppen sind «Interne Parasiten», «Tumore» oder «Dermatologische Erkrankungen». Jede dieser Gruppen enthält spezifische Krankheiten, wie z. B. Hakenwürmer (in der Gruppe «Interne Parasiten»), Prostatakrebs (in der Gruppe «Tumore») oder atopische Dermatitis (in der Gruppe «Dermatologische Erkrankungen»).

Informationen zu Hunden

Die Rasse eines Hundes ist ein wichtiger Faktor, da manche Rassen anfälliger für bestimmte Krankheiten sind. Zum Beispiel neigen Deutsche Schäferhunde eher zu Wirbelsäulenerkrankungen, während Französische Bulldoggen häufiger Atemprobleme und Hauterkrankungen haben. Fetchs Datensatz enthält

über 500 verschiedene Hunderassen, die zur besseren Analyse in Gruppen mit ähnlicher Genetik und Krankheitsanfälligkeiten eingeteilt wurden. Ausserdem wurden weitere Merkmale wie Grösse, Haarlänge und Verhalten (z. B. Temperament, Energielevel des Hundes oder Trainierbarkeit) berücksichtigt, die rassenübergreifend mit bestimmten Krankheiten in Verbindung stehen.

Umgebung

Manche Krankheiten, wie Hautkrankheiten und Arthrose, stehen in Verbindung mit Umweltfaktoren wie Klima und Bevölkerungsdichte. Deshalb wurden externe Daten hinzugefügt, die basierend auf der Postleitzahl Informationen wie Bevölkerungsdichte, mittleres Einkommen, durchschnittliche Temperaturen, die Anzahl sehr heisser oder kalter Tage pro Jahr und Regenhäufigkeit umfassen.

Der KI-Ansatz

Im Zentrum unseres Ansatzes steht ein KI-Modell (Debes et al., 2023), das auf Basis aller vorhandenen Daten zu einem Hund und seiner Umgebung die Wahrscheinlichkeit für das Auftreten von 48 verschiedenen Krankheitsgruppen im nächsten Jahr vorhersagt. Durch entsprechende Erweiterungen kann das Vorhersagefenster dann auf eine beliebige Anzahl an Jahren erhöht werden. Der Prozess zum Trainieren dieses Modells umfasst mehrere Schritte, die im Folgenden detailliert beschrieben werden:

1. Vorverarbeitung und Anreicherung

In der ersten Phase haben wir alle Daten eines Hundes in eine Zeitreihe umgewandelt, die sowohl vergangene Versicherungsfälle als auch Vorerkrankungen

abbildet. Diese Zeitreihen wurden um verschiedene Parameter angereichert, wie zum Beispiel die Rasse des Hundes, spezifische Eigenschaften der Rasse, sowie Umgebungsvariablen wie klimatische Bedingungen und soziodemografische Daten des Wohnortes.

2. Vorbereitung des Trainings

Um eine objektive Bewertung des Modells zu gewährleisten, wurden die Daten in Trainings- und Testdaten unterteilt. Das Ziel dieser Trennung ist es, das Modell auf einem Teil der Daten zu trainieren und seine Leistung auf einem anderen, ungesehenen Teil zu evaluieren. Dabei wurde darauf geachtet, dass die Verteilung von wichtigen Merkmalen wie Rasse, Alter und Vorerkrankungen in beiden Datensätzen ähnlich ist, um Verzerrungen zu vermeiden. Eine gleichmässige Verteilung dieser Merkmale ist entscheidend, um sicherzustellen, dass das Modell auf verschiedene Szenarien verallgemeinern kann und nicht nur auf bestimmte Subgruppen der Daten abgestimmt ist.

3. Training

Während des Modelltrainings haben wir die Daten so aufbereitet, dass sie in verschiedene Zeitfenster unterteilt wurden. Ein Zeitfenster repräsentiert die Vergangenheit (z. B. alle Informationen über die ersten vier Jahre eines fünfjährigen Hundes), während ein separates Zeitfenster die vorherzusagende Zukunft darstellt (z. B. das fünfte Jahr eines fünfjährigen Hundes). Diese Methode der Aufteilung in zahlreiche mögliche Zeitfenster ermöglicht es, das Modell mit einer grösseren Datenmenge zu trainieren und dadurch seine Vorhersagegenauigkeit zu steigern.

Eine Vielzahl an möglichen Machine-Learning-Modellen, die für die Verarbeitung tabellarischer Daten geeignet sind (und gleichzeitig Erklärbarkeit bieten) wurden ausgewählt – sie beinhalteten Modelle wie XGBoost, LightGBM, Random Forest und andere Methoden, die auf Entscheidungsbäumen basieren.

4. Evaluation

Die Evaluation des Modells wurde auf den ungesehenen Testdaten durchgeführt. Hierfür wurde die Metrik «Area Under the Curve» (AUC) verwendet, die besonders gut geeignet ist für unausgewogene Klassifizierungsprobleme wie unseres, bei dem einige Krankheiten viel häufiger auftreten als andere. Eine AUC von 50 % würde auf ein Modell hinweisen, das nicht besser ist als Zufall, während eine AUC von 100 % auf perfekte Vorhersagen hinweist. Das beste Modell in unserem Fall erreichte eine AUC von 81 %, was einer sehr hohen Genauigkeit und Zuverlässigkeit der Vorhersagen entspricht.

5. Inferenz

Nachdem das Modell trainiert und evaluiert wurde, kann es nun für Vorhersagen auf neuen, bisher ungesehenen Daten verwendet werden.

Ein wesentlicher Aspekt unseres Ansatzes war die Implementierung von sogenannter «erklärbarer KI». Unter erklärbarer KI versteht man Methoden, die es ermöglichen, die Entscheidungen eines KI-Modells transparent und nachvollziehbar zu machen. Diese Transparenz ist besonders wichtig, um Vertrauen bei den Nutzern des Modells und Experten zu schaffen und sicherzustellen, dass die KI sinnvolle und wissenschaftlich fundierte Zusammenhänge lernt. In unserem Projekt haben wir erklärbare KI-Techniken eingesetzt, um gemein-

sam mit Veterinär-Epidemiologen und Tierärzten das Modell zu analysieren und zu validieren. Durch diese Zusammenarbeit konnten wir überprüfen, wie das Modell verschiedene Faktoren, wie das Alter des Hundes, die Kombination von Rasse und Vorerkrankungen sowie andere relevante Merkmale, interpretiert und gewichtet.

Dies führte dazu, dass wir in mehreren Iterationen das Modell weiter verfeinern konnten, um die Vorhersagen noch präziser und vertrauenswürdiger zu machen. Dank der hohen AUC von 81 % und der zusätzlichen Validierung durch Experten aus der Tiermedizin wurde das Modell schliesslich in der renommierten Zeitschrift «Nature – Scientific Reports» [3] veröffentlicht. Neben der praktischen Anwendbarkeit und Zuverlässigkeit in der realen Welt unterstreicht diese Veröffentlichung auch die wissenschaftliche Bedeutung des Modells.

Die Anwendungen

Unser Ansatz beruht auf einer Vielzahl von Informationsquellen, um genaue und personalisierte Krankheitsvorhersagen für Hunde zu ermöglichen. Wir verfolgen hierbei keinen Use Case-fokussierten Ansatz (der also ein Modell für einen individuellen Anwendungsfall optimieren würde), sondern einen API-fokussierten Ansatz (der ein Modell mit hoher Flexibilität, Robustheit und Qualität für eine Vielzahl an Anwendungen bereitstellt).

Dieser Abschnitt beleuchtet den Datenfluss, die Bereitstellung des Modells (siehe [Abbildung 1 – Model Training](#)) sowie die verschiedenen Anwendungsfälle, die durch eine flexible API unterstützt werden (siehe [Abbildung 1 – Model API](#)).

Datenfluss und Bereitstellung des Modells

Wie bereits oben beschrieben, basiert unser Modell auf umfangreichen Eingangsdaten, die in drei Hauptkategorien unterteilt sind:

- Policies: Diese umfassen Vertragsinformationen und Basisdaten wie Hunderasse, Alter, Geschlecht und Wohnort.
- Claims: Hierbei handelt es sich um eingereichte Versicherungsfälle, die wichtige Details wie Zeitpunkt, Diagnose und Behandlung der Erkrankungen enthalten.
- Externe Datenquellen: Beispielsweise Informationen über spezifische Hunderassencharakteristika, klimatische Bedingungen und demografische Daten der Wohngebiete.

Diese Eingangsdaten werden in einer mit Veterinären entwickelten Ontologie zusammengeführt, die als Grundlage für das Modelltraining dient. Diese Ontologie ermöglicht es, die Daten auf eine strukturierte Weise zu organisieren, sodass das Modell effektiver lernen und genauere Vorhersagen treffen kann. Die Bereitstellung des Modells erfolgt über ein sogenanntes Model Registry, das sicherstellt, dass die Modelle stets aktuell und zugänglich sind. Darüber hinaus werden täglich Populationstatistiken basierend auf den vorhandenen Versicherungsfällen und den versicherten Hunden berechnet sowie bereitgestellt. (siehe [Abbildung 1](#) – Model Training)


Beschreibung der API und ihrer Anwendungsfälle

Die API wurde entwickelt, um eine Vielzahl von Anwendungsfällen zu unterstützen, sowohl intern innerhalb von Fetch als auch extern für existierende und potenzielle Kunden. Hierbei unterscheidet die API zwischen verschiedenen Detailgraden der Eingangsdaten:

- Minimale Eingangsdaten: Hier sind nur grundlegende Informationen wie die Hunderasse oder eine spezifische Krankheit bekannt. Dieses Szenario ist typisch für externe Anwendungen, bei denen nur limitierte Informationen zur Verfügung stehen.
- Moderate Eingangsdaten: Neben der Rasse sind auch Alter und einige Vorerkrankungen bekannt, jedoch ohne detaillierte Diagnoseinformationen. Diese Datenlage ermöglicht bereits genauere Vorhersagen.

Abb. 1: Datenflussdiagramm mit Modell-Training und Modell-API und Applikationen

Quelle: Eigene Darstellung



- Vollumfängliche Eingangsdaten: In diesem Fall liegen alle relevanten Daten vor, einschliesslich detaillierter Versicherungsinformationen. Dies ist typischerweise bei internen Anwendungen der Fall, bei denen auf die vollständige Datenbasis von Fetch zurückgegriffen werden kann.

Ein zentrales Element der API ist das Decision Layer, das automatisch das am besten geeignete Modell auswählt, basierend auf den vorhandenen Eingangsdaten. Mögliche Modelle sind:

- Breed Level: Liefert Populationsstatistiken zu Krankheiten basierend auf einer ausgewählten Hunderasse.
- Disease Level: Liefert Populationsstatistiken zu Hunderassen basierend auf einer ausgewählten Krankheit.
- Individual Level: Nutzt mindestens zwei Eingangsparameter wie Rasse, Alter, Wohnort oder Vorerkrankungen, um individuelle Vorhersagen zu erstellen.
- Policy Level: Nutzt detaillierte Versicherungsinformationen, um präzise Krankheitswahrscheinlichkeiten für den individuellen Hund zu berechnen.

Beispiele für Anwendungsfälle

Gemeinsam mit Fetch haben wir verschiedene Anwendungsfälle umgesetzt:

- Veterinär-Portal: Diese Anwendung ermöglicht es Tierärzten, spezifische Informationen zu bestimmten Rassen oder Krankheiten abzurufen. Das Portal dient als zusätzliche Informationsquelle im Gespräch mit den Hundebesitzern und unterstützt datengestützt das Patientengespräch.
- Interne Anwendungen: Diese nutzen die komplette Datenbasis von Fetch, um detaillierte und personalisierte Vorhersagen zu Krankheitsrisiken zu erstellen. Dies unterstützt den Kundenservice und den Verkaufs-

prozess, indem Versicherungsagenten detaillierte Risikoeinschätzungen für Hunde geben können.

- Externe Anwendungen: Ein Beispiel ist der «Fetch Health Forecast», der es allen Hundehaltern ermöglicht, einen Gesundheitsbericht für ihren Hund zu erstellen. Durch die Eingabe von Parametern wie Rasse, Alter, Geschlecht und Vorerkrankungen wird ein Bericht erstellt, der die Krankheitswahrscheinlichkeiten für die kommenden Jahre und passende, individualisierte Ratschläge aufzeigt. Der Bericht gibt zudem auch Ratschläge zur Hundehaltung. Sind die Hundehalter zugleich noch Versicherungsnehmer bei Fetch, erhalten sie noch genauere Vorhersagen.

Abbildung 2 zeigt den ersten Teil des Berichts, der personalisierte Informationen über den Hund und darunter die Vorhersagen der wahrscheinlichsten von 48 Krankheiten in den nächsten drei Jahren zeigt. Es wird dabei zwischen bereits bekannten Vorerkrankungen und Vorhersagen noch unbekannter Krankheiten unterschieden. Zudem bietet der Bericht detaillierte Informationen zu möglichen Ursachen, Anzeichen, Vorbeugungsmassnahmen, Diagnosen, Behandlungen und Kosten, welche in Zusammenarbeit mit den Tierärzten erarbeitet und erstellt wurden (Abbildung 3).

Abb. 2: Fetch Health Forecast (1/2) – Profil und Krankheitsvorhersagen

Quelle: Fetch Pet Insurance




Abb. 3: Fetch Health Forecast (2/2) – Krankheitsinformationen

Quelle: Fetch Pet Insurance



Fazit

Künstliche Intelligenz bietet riesige Chancen, existierende Versicherungsdaten zu veredeln und neuartige Geschäftsmodelle zu entwickeln. Ein Modell allein schafft dabei keinen Mehrwert – es sind die vielseitigen Anwendungsfälle, die es wirklich nützlich machen. Zwei Elemente sind aus unserer Sicht für den Erfolg nötig:

- Ein API-basierter Ansatz, der flexible KI-Modelle als Basistechnologie bereitstellt und es erlaubt, viele verschiedene Ideen in kurzer Zeit umzusetzen und zu testen. Unterschiedliche Geschäftsbereiche haben dadurch Use Cases rund um das Modell entwickelt und vorangetrieben. Weitere Ideen sind in Arbeit, während im Hintergrund das Modell kontinuierlich verbessert und verfeinert werden kann.

- Der Einsatz von erklärbarer KI, der es ermöglicht hat, Vertrauen in das entwickelte Modell aufzubauen. Anstatt eine Black Box zu sein, handelt es sich bei diesem Modell um ein transparentes, sich kontinuierlich selbsterklärendes System. Dadurch wird es möglich, dessen Funktionsweise zu verstehen, zu hinterfragen und bei Bedarf anzupassen. Ohne solche Verfahren ist es unserer Meinung nach nicht möglich, echtes Vertrauen in künstliche Intelligenz zu schaffen, wodurch die Technik hinter ihren Möglichkeiten zur Mehrwertgewinnung zurückbliebe.

Autoren



Dr. Christian Debes
ist Gründer und Head of Data Analytics & AI bei Spryfox, sowie Lehrbeauftragter an der Technischen Universität Darmstadt.



Johannes Wowra
ist Gründer und Head of Software Development & IoT bei Spryfox.



Referenzen

- Allied Market Research. (2024). Pet insurance market size, share, competitive landscape and trend analysis report, by policy coverage, by animal type, by sales channel: global opportunity analysis and industry forecast, 2024-2033.
Abgerufen von <https://www.alliedmarketresearch.com/pet-insurance-market>.
- Cohen S. P. (2002). Can pets function as family members? Western journal of nursing research, 24(6), 621–638.
- Debes, C., Wowra, J., Manzoor, S., & Ruple, A. (2023). Predicting health outcomes in dogs using insurance claims data. Scientific Reports, 13(1), 9122.