Aus dem Department für Kleintiere und Pferde
Anästhesiologie und perioperative Intensivmedizin der
Veterinärmedizinischen Universität Wien
LeiterIn: Privat.-Doz. Dr. med. vet. Ulrike Auer

Monitoring der Aufwachphase beim Pferd

Vergleich einer Video Analyse mit einer Orientierungs- und Höhenmessung am Kopf mit einem drahtlosen Sensor

Diplomarbeit

Veterinärmedizinische Universität Wien

vorgelegt von Julia Claus

Wien, im März 2021

BetreuerIn:

Privat.-Doz. Dr. med. vet. Ulrike Auer

Klinische Abteilung für Anästhesiologie und Intensivmedizin

Dipl.–Ing. Dr. med. vet. Johannes Schramel

Klinische Abteilung für Pferdechirurgie

Danksagung

An dieser Stelle möchte ich mich bei den besten Eltern der Welt bedanken, ohne die mein Studium in dieser unbeschwerten Form nicht möglich gewesen wäre. Egal um was es ging, ich wurde immer unterstützt und nie alleine gelassen.

Ein ehrenvoller Dank geht an meine Oma Ami, die mich ebenfalls finanziell, sowie von allen anderen Seiten unterstützt hat. Leider kann sie meinen Abschluss nicht mehr miterleben.

Mein besonderer Dank geht an meine bessere Hälfte, die mich in allen Höhen und Tiefen des Studiums unterstützt und motiviert hat. Ohne dich wäre der technische Teil der Arbeit nicht möglich gewesen. Ich liebe dich.

Auch möchte ich mich bei meiner Betreuerin Dr. Ulrike Auer und meinem Betreuer Dr. Johannes Peter Schramel für die verständnisvolle, angenehme Zusammenarbeit und das Bereitstellen der Daten bedanken.

Inhaltsverzeichnis

1. Einleitung **1**

2. Hypothese **3**

3. Material **4**
3.1. Studienteilnehmer . . . 4
3.2. Gerätebeschreibung des Sensors X-DOF . . . 4
3.3. Beschreibung der Sensordaten . . . 4
3.4. Export der Sensordaten in Exceldateien . . . 6
3.5. Videos der postoperativen Aufwachphase . . . 7
3.6. Auswertung der Videos . . . 7
3.7. Zusammenführung der Sensordaten und Daten der Videoanalyse . . . 10

4. Methode **12**
4.1. Datenvisualisierungen . . . 12
4.1.1. Darstellung der Videoanalysedaten anhand numerischer Werte . . . 12
4.1.2. Darstellung der X-DOF Daten in Kombination mit den zugehörigen Videoanalysedaten . . . 13
4.1.3. t-distributed stochastic neighbor embedding . . . 13
4.2. Maschinelles Lernen . . . 14
4.2.1. Vorbereitung der Daten . . . 15
4.2.2. Erstellung der Training- und Testdatensätze . . . 15
4.2.3. Aufbau des neuronalen Netzes . . . 16

5. Ergebnisse **19**
5.1. Auswertung der Datenvisualisierungen . . . 19
5.1.1. Darstellung der Videoanalysedaten anhand numerischer Werte . . . 19
5.1.2. Darstellung der X-DOF Daten in Kombination mit den zugehörigen Videoanalysedaten . . . 21
5.1.3. t-distributed stochastic neighbor embedding . . . 25
5.2. Maschinelles Lernen . . . 27
5.2.1. Korrelationsmatrix . . . 27
5.2.2. Auswertung des trainierten neuronalen Netzes . . . 28

6. Diskussion **31**

7. Zusammenfassung **34**

8. Extended summary **35**

Literatur **36**

A. Zuordnungen von Auswertungskriterien zu numerischen Werten **38**

B. Originale Sensordaten inklusive angepasster Wert für alt **40**

C. Darstellung der Videoanalysedaten anhand numerischer Werte **50**

D. Sensordaten eingefärbt für Kategorie Lage **51**

E. Sensordaten reduziert durch t-SNE **60**

Abbildungsverzeichnis

1. Visualisierung von *yaw*, *pitch* und *roll* am Pferdekopf. 5
2. Beispiel eines Excel Tabellenblatts der *X-DOF* Werte 7
3. Beispiel eines Excel Tabellenblatts der Videoauswertung 11
4. Ausschnitt von Graphen zu allen Sensorwerten und dem Graphen zu Kategorie Lage. 20
5. Ausschnitt von Graphen zu allen Sensorwerten, eingefärbt für Lage. . . . 22
6. Ausschnitt von Graph zu yaw Werten, eingefärbt für Kopfbewegung (horizontal) 24
7. Ausschnitt von Graph zu pitch Werten, eingefärbt für Kopfbewegung (vertikal) 24
8. Sensordaten reduziert durch t-SNE, mit Klassifizierung für Lage 26
9. Korrelationsmatrix der verwendeten Features 28
10. Konfusionsmatrix (Testdatensatz **Pferd 1**) 29
11. **Pferd 1** — Werte für *yaw* 40
12. **Pferd 1** — Werte für *pitch* 40
13. **Pferd 1** — Werte für *roll* 40
14. **Pferd 1** — Werte für *dphi* 41
15. **Pferd 1** — Werte für *alt* 41
16. **Pferd 1** — angepasste Werte für *alt* 41
17. **Pferd 2** — Werte für *yaw* 42
18. **Pferd 2** — Werte für *pitch* 42
19. **Pferd 2** — Werte für *roll* 42
20. **Pferd 2** — Werte für *dphi* 43
21. **Pferd 2** — Werte für *alt* 43
22. **Pferd 2** — angepasste Werte für *alt* 43
23. **Pferd 3** — Werte für *yaw* 44
24. **Pferd 3** — Werte für *pitch* 44
25. **Pferd 3** — Werte für *roll* 44
26. **Pferd 3** — Werte für *dphi* 45
27. **Pferd 3** — Werte für *alt* 45
28. **Pferd 3** — angepasste Werte für *alt* 45
29. **Pferd 4** — Werte für *yaw* 46
30. **Pferd 4** — Werte für *pitch* 46

31. **Pferd 4** — Werte für *roll* . . . 46
32. **Pferd 4** — Werte für *dphi* . . . 47
33. **Pferd 4** — Werte für *alt* . . . 47
34. **Pferd 4** — angepasste Werte für *alt* . . . 47
35. **Pferd 5** — Werte für *yaw* . . . 48
36. **Pferd 5** — Werte für *pitch* . . . 48
37. **Pferd 5** — Werte für *roll* . . . 48
38. **Pferd 5** — Werte für *dphi* . . . 49
39. **Pferd 5** — Werte für *alt* . . . 49
40. **Pferd 5** — angepasste Werte für *alt* . . . 49
41. **Pferd 5** — Zugeordnete Werte für Kategorie Lage . . . 50
42. **Pferd 5** — Zugeordnete Werte für Kategorie Kopfbewegung (horizontal) 50
43. **Pferd 5** — Zugeordnete Werte für Kategorie Kopfbewegung (vertikal) . . 50
44. **Pferd 5** — Zugeordnete Werte für Kategorie Drehung im Raum 50
45. **Pferd 1** — Werte für *yaw*, eingefärbt für Kategorie Lage . . . 51
46. **Pferd 1** — Werte für *pitch*, eingefärbt für Kategorie Lage . . . 51
47. **Pferd 1** — Werte für *roll*, eingefärbt für Kategorie Lage . . . 51
48. **Pferd 1** — Werte für *dphi*, eingefärbt für Kategorie Lage . . . 51
49. **Pferd 1** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage 51
50. **Pferd 2** — Werte für *yaw*, eingefärbt für Kategorie Lage . . . 52
51. **Pferd 2** — Werte für *pitch*, eingefärbt für Kategorie Lage . . . 52
52. **Pferd 2** — Werte für *roll*, eingefärbt für Kategorie Lage . . . 52
53. **Pferd 2** — Werte für *dphi*, eingefärbt für Kategorie Lage . . . 53
54. **Pferd 2** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage 53
55. **Pferd 3** — Werte für *yaw*, eingefärbt für Kategorie Lage . . . 54
56. **Pferd 3** — Werte für *pitch*, eingefärbt für Kategorie Lage . . . 54
57. **Pferd 3** — Werte für *roll*, eingefärbt für Kategorie Lage . . . 54
58. **Pferd 3** — Werte für *dphi*, eingefärbt für Kategorie Lage . . . 55
59. **Pferd 3** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage 55
60. **Pferd 4** — Werte für *yaw*, eingefärbt für Kategorie Lage . . . 56
61. **Pferd 4** — Werte für *pitch*, eingefärbt für Kategorie Lage . . . 56
62. **Pferd 4** — Werte für *roll*, eingefärbt für Kategorie Lage . . . 56
63. **Pferd 4** — Werte für *dphi*, eingefärbt für Kategorie Lage . . . 57
64. **Pferd 4** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage 57
65. **Pferd 5** — Werte für *yaw*, eingefärbt für Kategorie Lage . . . 58
66. **Pferd 5** — Werte für *pitch*, eingefärbt für Kategorie Lage . . . 58
67. **Pferd 5** — Werte für *roll*, eingefärbt für Kategorie Lage . . . 58
68. **Pferd 5** — Werte für *dphi*, eingefärbt für Kategorie Lage . . . 59
69. **Pferd 5** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage 59
70. Sensordaten reduziert durch t-SNE, mit Klassifizierung für Drehung . . . 60
71. Sensordaten reduziert durch t-SNE, mit Klassifizierung für Kopfbewegung (vertikal) . . . 61
72. Sensordaten reduziert durch t-SNE, mit Klassifizierung für Kopfbewegung (horizontal) . . . 62

Tabellenverzeichnis

1. Definitionen der Kategorie Lage 8
2. Definitionen der Kategorie Drehung im Raum 9
3. Definitionen der Kategorie Kopfbewegung (vertikal) 9
4. Definitionen der Kategorie Kopfbewegung (horizontal) 10
5. Zuordnungen der Kategorie Lage zu numerischen Werten 38
6. Zuordnungen der Kategorie Drehung im Raum zu numerischen Werten . 38
7. Zuordnungen der Kategorie Kopfbewegung (vertikal) zu numerischen Werten 39
8. Zuordnungen der Kategorie Kopfbewegung (horizontal) zu numerischen Werten 39

1. Einleitung

In der Humanmedizin sterben im Durchschnitt 0,4/100.000 (Gottschalk u. a. 2011) PatientInnen, bei denen eine Allgemeinanästhesie durchgeführt wurde. In der Kleintiermedizin liegt die Mortalitätsrate bei durchgeführten Allgemeinanästhesien bei 0,1 bis 0,2% und bei Anästhesien mit bekanntem Risiko bei 0,5 – 2% (Brodbelt 2009). Der Bereich der Pferdemedizin hat mit weitaus größeren Mortalitätsraten umzugehen. Hier stirbt ein Pferd von 111, somit liegt die Mortalitätsrate für Allgemeinanästhesien, die nicht mit Kolik assoziiert sind, bei 0,9% (Wagner 2008). Neben Hypotension, Hypovolämie, Hypokapnie, Hypoxämie (präoperativ und intraoperativ) ist ein entscheidender Faktor die postoperative Aufwachphase. Auftretende Probleme sind Myopathien, Neuropathien, Gewebeschäden, Atemwegsobstruktionen durch Anschwellen der Nasenschleimhaut, sowie Frakturen, die durch unkontrolliertes Aufstehen verursacht werden. In 26-64% (Dugdale und Taylor 2016; Young und Taylor 1993; Bidwell u. a. 2007) aller Todesfälle sind Frakturen Ursache für ein postoperatives Sterben oder Euthanasieren.

Für eine effiziente Analyse der Körperbewegungen des Pferdes während der Aufwachphase, ist es sinnvoll eine Methode zu verwenden, die es ermöglicht auswertbare Bewegungsdaten automatisch aufzuzeichnen. Bereits in verschiedenen Studien wurden Sensordaten als Basis für Bewegungsanalysen verwendet. Maisonpierre u. a. (2019) demonstrierten beispielsweise, dass mit Hilfe von Accelerometerdaten unterschiedliche Aktivitäten von Pferden (wie Stehen, Bewegung auf der Weide und geführte Bewegung) differenziert werden können. In einer Studie von Fries u. a. (2017) konnte ein linearer Zusammenhang zwischen der Bewegungshäufigkeit, die aus Accelerometerdaten gewonnen wurde und der zum jeweiligen Zeitpunkt klassifizierten Gangart nachgewiesen werden. In einer weiteren Studie (Eerdekens u. a. 2020) wurden klassifizierte Sensordaten (mit den Klassen Schritt, Trab, Galopp) eines *Accelerometers* genutzt, um ein neurales Netzwerk zu trainieren, um anschließend mit dem trainierten Algorithmus die Sensordaten automatisch der passende Klasse zuordnen zu können. In dieser Studie konnten mit einer sehr hohen Genauigkeit

(99%), unabhängig von Faktoren wie Untergrund oder Pferderasse, die genannten Gangarten bei den Testdatensätzen bestimmt werden.

Die vorliegende Arbeit ist eine Pilotstudie, die sich mit der postoperativen Aufwachphase des Pferdes nach Allgemeinanästhesie beschäftigt. Hierzu wurde die Bewegung des Pferdes in der Aufwachphase sensorbasiert protokolliert und mit Hilfe einer sekundengenauen Videoauswertung klassifiziert. Ziel der Arbeit ist es, auf Basis der Sensorwerte eine Aussage bezüglich der Körperbewegung während der Aufwachphase (z.B. Stand) zu treffen. Dies würde ermöglichen, mit Sensoren die Aufwachphase zu überwachen, objektiv zu quantifizieren und in Folge Aufwachphasen nach unterschiedlichen Anästhesieprotokollen besser und genauer zu beurteilen.

2. Hypothese

Für die vorliegende Arbeit wurde die postoperative Aufwachphase verschiedener Pferde nach durchgeführter Allgemeinanästhesie sensorbasiert überwacht. Ein auf Basis solcher Sensorwerte trainiertes neuronales Netz ist in der Lage die dazugehörigen Aktivitäten (bezüglich der Kategorien Lage, Drehung, Kopfbewegung (vertikal) und Kopfbewegung (horizontal)) zu bestimmen.

3. Material

3.1. Studienteilnehmer

Es wurden sechs Pferde während der Aufwachphase nach einer geplanten Allgemeinanästhesie und Operation an der Veterinärmedizinischen Universität Wien analysiert. Hierfür wurden keine speziellen Auswahlkriterien berücksichtigt. Für eines der Pferde existiert keine zeitliche Überschneidung zwischen den Sensor- und den Videodaten. Aus diesem Grund konnten diese Daten für die Analyse nicht verwendet werden und wurden aussortiert.

3.2. Gerätebeschreibung des Sensors X-DOF

Um die Lage, sowie Kopfbewegung des Pferdes bestimmen zu können, wird ein Sensor am Halfter zwischen den Ohren des Pferdes befestigt. Intern besteht der Sensor mit dem Namen *X-DOF* aus einem *Accelerometer*, einem *Gyroskop* und einem *Magnetometer* welche jeweils dreidimensionale Werte liefern Weiterhin ist ein *Barometer* integriert, über welches die Höhe bestimmt wird. Für die Summe der gemessenen Werte ergeben sich somit die namensgebenden zehn Freiheitsgrade — X, als römische Zahl Zehn, sowie DOF als Abkürzung für degrees of freedom. Der Sensor *X-DOF* wurde von Dipl.–Ing. Dr. med. vet. Johannes Schramel entwickelt.

3.3. Beschreibung der Sensordaten

Auf Basis der von den Sensoren *Accelerometer*, einem *Gyroskop* und einem *Magnetometer* gemessenen Daten, werden mithilfe eines Mikrocontrollers Werte für *roll*, *pitch*, *yaw* (die absolute Orientierung im Raum), sowie Delta Phi berechnet und von dem Sensor *X-DOF* ausgegeben. Die Abtastrate des Sensors beträgt 1 Hz (Hertz), das heißt die Sensordaten werden 1-mal pro Sekunde ausgelesen.

Roll bezeichnet die Drehung um die Längsachse, *pitch* die Drehung um die Querachse und *yaw* die Drehung um die Hochachse. Die gemessenen Werte geben den Winkel in

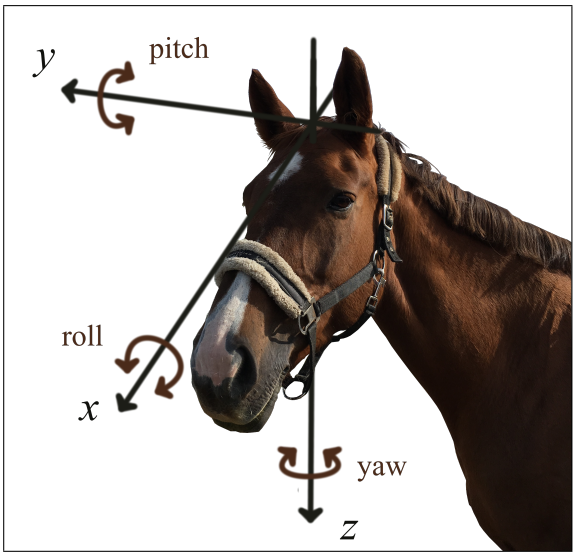

Abbildung 1: Visualisierung von *yaw*, *pitch* und *roll* am Pferdekopf.
(Quelle: selbst erstellte Abbildung auf Basis eigener Aufnahme (eigenes Pferd))

Grad der aktuellen Ausrichtung des Kopfes in Bezug auf die jeweilige Achse an. Die Wertebereiche von *roll* und *pitch* sind jeweils -180 bis 180 Grad und der Wert 0 Grad wird jeweils angenommen, wenn der Kopf des Pferdes parallel zum Boden ausgerichtet ist. Bei Werten für *roll* kleiner 0 Grad, ist der Kopf des Pferdes nach links, bei Werten größer 0 nach rechts geneigt. Pitch nimmt Werte größer 0 Grad an, wenn der Kopf gehoben ist, kleiner 0 Grad, wenn der Kopf gesenkt ist. Der Wertebereich von *yaw* ist 0 bis 360 Grad, wobei der Wert 0 Grad Norden entspricht. Der Wert Delta Phi — vom Sensor als *dphi* ausgegeben — gibt die Winkeländerung im Raum zwischen zwei aufeinanderfolgenden Datenpunkten an. Die Genauigkeit der Werte liegt aufgrund der Messtoleranz der Sensoren bei ± 2 Grad. Hierzu kommt noch die Befestigung der Sensoren am Kopf, die zu weiteren Messungenauigkeiten im Bereich von etwa ± 5 Grad führt. Für eine graphische Darstellung vergleiche Abbildung 1.

Mithilfe des Barometers wird die Höhe in der Einheit Zentimeter bestimmt. Der Sensor gibt den Wert in der Variablen *alt* (engl. *altitude*) aus. Die Höhe 0 cm wird angenommen, wenn der Kopf des Pferdes auf dem Boden liegt. Prinzipbedingt driftet der Wert dieses Sensors jedoch mit der Zeit weg, da der Luftdruck über lange Dauer nicht konstant ist. Laut

Entwickler liegt die Genauigkeit innerhalb eines Zeitraums von 5 bis 10 Sekunden bei ca. $\pm$15 cm. Erreicht die Höhe aufgrund des Drifts einen Wert größer als 500 cm, wird der Wert zurück auf 0 cm gesetzt.

Teilweise muss der Sensor sich selbst neu kalibrieren. Dies teilt die Software des Sensors über die Variable *stat* (für Status) mit. Nimmt diese einen Wert kleiner 2 an, sind die Messwerte nicht verwendbar.

In dieser Pilotstudio wurde der Sensor *X-DOF* nur am Kopf des Pferdes befestigt. Durch diese Positionierung beziehen sich die Werte auf die Lageänderung des Kopfes. Einen direkten Rückschluss auf den Grund der Lageänderung lassen die einzelnen Werte nicht zu. Beispielsweise könnte eine Änderung der Höhe durch den Aufstehversuch des Pferdes bedingt werden oder aber durch das Heben des Kopfes. Das heißt der Sensor *X-DOF* protokolliert nicht, ob sich ausschließlich der Kopf bewegt oder ob sich das Pferd bewegt und dies zu einer Lageänderung des Kopfes geführt hat.

3.4. Export der Sensordaten in Exceldateien

Die vom *X-DOF* Sensor ausgegebenen Werte *yaw*, *pitch*, *roll*, *dphi*, *alt*, sowie *stat* wurden via Bluetooth auf einen Computer übertragen und in einer Exceldatei gespeichert. Jeder Tabelleneintrag wird zudem automatisch mit einem Zeitstempel, auf Basis der Windows-Systemzeit, ergänzt.

Wie in Abschnitt 3.3 beschrieben, wird sobald das Barometer einen Wert größer als 500 cm misst, dieser innerhalb des Sensors zurück auf 0 cm gesetzt. Um diesen Schritt rückgängig zu machen, wurde zunächst die Spalte `alt` in eine neue Spalte `alt_original` kopiert. In der ursprünglichen Spalte `alt` wurden anschließend alle Werte ab der Zeile, in der die Höhe auf den Wert auf 0 zurückgesetzt wurde, mit 500 addiert.

Für ein Beispiel eines solchen Excel Tabellenblatts vergleiche Abbildung 2.

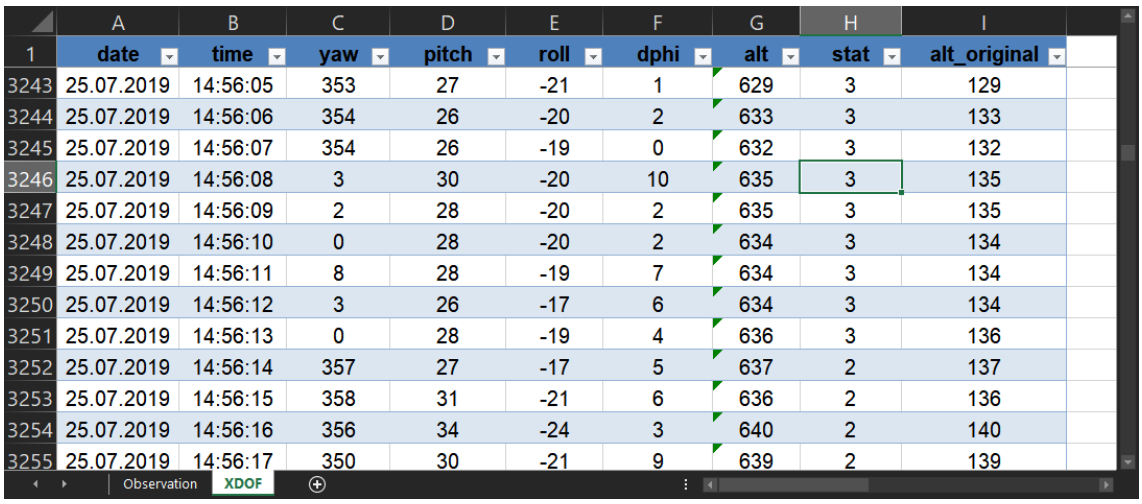

	A	B	C	D	E	F	G	H	I
1	date	time	yaw	pitch	roll	dphi	alt	stat	alt_original
3243	25.07.2019	14:56:05	353	27	-21	1	629	3	129
3244	25.07.2019	14:56:06	354	26	-20	2	633	3	133
3245	25.07.2019	14:56:07	354	26	-19	0	632	3	132
3246	25.07.2019	14:56:08	3	30	-20	10	635	3	135
3247	25.07.2019	14:56:09	2	28	-20	2	635	3	135
3248	25.07.2019	14:56:10	0	28	-20	2	634	3	134
3249	25.07.2019	14:56:11	8	28	-19	7	634	3	134
3250	25.07.2019	14:56:12	3	26	-17	6	634	3	134
3251	25.07.2019	14:56:13	0	28	-19	4	636	3	136
3252	25.07.2019	14:56:14	357	27	-17	5	637	2	137
3253	25.07.2019	14:56:15	358	31	-21	6	636	2	136
3254	25.07.2019	14:56:16	356	34	-24	3	640	2	140
3255	25.07.2019	14:56:17	350	30	-21	9	639	2	139

Observation XDOF

Abbildung 2: Beispiel eines Excel Tabellenblatts der *X-DOF* Werte

3.5. Videos der postoperativen Aufwachphase

Die Aufwachphase der Pferde wurde zusätzlich mithilfe von zwei Überwachungskameras aufgezeichnet und in einem proprietären Format gespeichert, das für die Analyse in das Format *h.264* konvertiert wurde. Die Videos sind, so wie die in Excel protokollierten Daten, mit einem Zeitstempel auf Basis der Windows-Systemzeit versehen. Bis auf potentielle minimale Unterschiede in der synchronisierten Windows-Systemzeit, sind somit die Videodaten vergleichbar mit Exceldaten, die denselben Zeitstempel besitzen.

3.6. Auswertung der Videos

Auf Basis der in Abschnitt 3.5 beschriebenen Videos wurde eine Videoanalyse durchgeführt, in der die beobachteten Aktivitäten protokolliert wurden. Angelehnt an die typischen Körperbewegungen eines Pferdes während der Aufwachphase wurde eine Liste von Events, die in der Videoanalyse beobachtet werden sollen, erstellt. Diese Events wurden in die vier Kategorien Lage (des Körpers), Drehung (des Körpers im Raum), Kopfbewegung (vertikal) und Kopfbewegung (horizontal) gegliedert.

Die Kategorie Lage enthält die Events Seitenlage, Ansatz Brust-Bauch-Lage, Übergang

Tabelle 1: Definitionen der Kategorie Lage

Kategorie	Definition
Seitenlage	bewegungsloses Liegen entweder auf der linken oder rechten Körperseite
Ansatz Brust-Bauch-Lage	Aufrichten des Kopfes und Halses in Richtung Brust-Bauch-Lage
Übergang Brust-Bauch-Lage	Anheben des Kopfes, Verlagerung des Körperschwerpunktes von der Seite in Richtung Mitte
Brust-Bauch-Lage	Kopf angehoben, Vorder- und Hintergliedmaßen eingeschlagen, liegen auf dem Bauch
Bauch vom Boden abgehoben	geringgradiges Abheben des Bauches vom Boden
Ansatz bis Vorderextremitäten gestreckt	Aufstehversuch, bei dem der Bauch vom Boden abgehoben ist und die Vorderextremitäten gestreckt werden
Beine gestreckt	Vorderextremitäten und Hinterextremitäten gestreckt, Vorstufe zum Stand
Hundesitzige Stellung	Sitzen auf dem Gesäß, Hintergliedmaßen eingezogen, Vordergliedmaße gestreckt, Kopf angehoben
Umlagerung auf andere Seite	Umlagerung von Linkseitenlage in Rechtsseitenlage und andersrum
Robben durch die Box	mit dem Bauch über den Boden gleiten in der Box
Stehen auf allen vier Gliedmaßen	Stehen auf allen vier Gliedmaßen

Brust-Bauch-Lage, Brust-Bauch-Lage, Bauch vom Boden abgehoben, Ansatz bis Vorderextremitäten gestreckt, Beine gestreckt, Hundesitzige Stellung, Umlagerung auf andere Seite, Robben durch die Box und Stehen auf allen vier Gliedmaßen (vgl. Tabelle 1).

Tabelle 2: Definitionen der Kategorie Drehung im Raum

Kategorie	Definition
0 Grad	Ausrichtung nach Norden
90 Grad	Ausrichtung im 90 Gradwinkel in Bezug auf Norden
180 Grad	Ausrichtung im 180 Gradwinkel in Bezug auf Norden
270 Grad	Ausrichtung im 270 Gradwinkel in Bezug auf Norden

Der Kategorie Drehung im Raum sind die Events 0 Grad, 90 Grad, 180 Grad und 270 Grad zugeordnet, welche die Momente beschreiben, in denen der Kopf des Pferd in den jeweiligen Winkeln in der Box ausgerichtet ist (vgl. Tabelle 2).

Tabelle 3: Definitionen der Kategorie Kopfbewegung (vertikal)

Kategorie	Definition
Kopfbewegung hoch	Kopfbewegung in vertikaler Achse nach oben
Kopfbewegung runter	Kopfbewegung in vertikaler Achse nach unten

Die zwei Events der Kategorie Kopfbewegung (vertikal) geben die Zeiträume an, in denen das Pferd den Kopf senkt, bzw. hebt (vgl. Tabelle 3).

Die Kategorie Kopfbewegung (horizontal) beinhaltet die Events Kopfbewegung nach rechts oder links, jeweils in den Lagen Liegen, Brust-Bauch-Lage und Stand (vgl. Tabelle 4).

Für die Analyse der Videos wurde auf Empfehlung zunächst das Computerprogramm Solomon Coder verwendet[1], mit Hilfe dessen eine sekundengenaue Videoauswertung durchgeführt werden kann. Aufgrund häufigen Auftretens von Programmfehlern während der Auswertung, wurde nach Absprache für die übrige Videoanalyse das Computerprogramm BORIS[2] eingesetzt, da für Solomon Coder keine Unterstützung mehr angeboten wird und

[1] Download sowie weitere Informationen des Programms Solomon Coder sind zu finden unter https://solomon.andraspeter.com.

[2] Download sowie weitere Informationen des Programms BORIS sind zu finden unter http://www.boris.unito.it. BORIS ist eine Abkürzung für Behavioral Observation Research Interactive Software.

Tabelle 4: Definitionen der Kategorie Kopfbewegung (horizontal)

Kategorie	Definition
Seitenlage Kopfbewegung rechts	Kopfbewegung nach rechts in einem Winkel größer gleich 45 Grad in Seitenlage
Seitenlage Kopfbewegung links	Kopfbewegung nach link in einem Winkel größer gleich 45 Grad in Seitenlage
Brust-Bauch-Lage Kopfbewegung rechts	Kopfbewegung nach rechts in einem Winkel größer gleich 45 Grad in Brust-Bauch-Lage
Brust-Bauch-Lage Kopfbewegung links	Kopfbewegung nach link in einem Winkel größer gleich 45 Grad in Brust-Bauch-Lage
Stehen Kopfbewegung rechts	Kopfbewegung nach rechts in einem Winkel größer gleich 45 Grad in Stehen
Stehen Kopfbewegung links	Kopfbewegung nach link in einem Winkel größer gleich 45 Grad in Stehen

BORIS eine vergleichbare Auswertung ermöglicht.

Für die oben genannten Auswertungskriterien (vgl. Tabellen 1 bis 4) wurden die Kategorien manuell in den genannten Programmen kodiert. Dies ermöglicht es jedem Videoframe, bzw. jeder Sekunde des Videos, die dort vorkommenden Körperbewegungen (siehe Abschnitt 3.6) manuell zuzuordnen. In diesem Punkt unterscheidet sich das Handling der beiden Programme. In dem Programm Solomon Coder wird pro Sekunde eine Beobachtung geloggt. Das Programm BORIS bietet die Möglichkeit punktuelle Beobachtungen zu protokollieren oder einem Zeitfenster mit einem Start- und einen Endzeitpunkt eine Beobachtung zuzuordnen. Da die beobachteten Ereignisse jeweils Zeitfenster betreffen, wurde ebendiese Möglichkeit für das Protokollieren dieser Ereignisse gewählt. Die fertigen Beobachtungen wurden anschließend in separate Exceldateien exportiert. Die Formatierung der exportierten Daten unterscheidet sich zwischen den beiden Programmen und wurde daher nach dem Export manuell angeglichen.

3.7. Zusammenführung der Sensordaten und Daten der Videoanalyse

Für die Analyse wurden die exportierten Beobachtungsdaten in der Exceldatei, die die Sensordaten des jeweiligen Pferdes enthält, in einem neuen Tabellenblatt ergänzt.

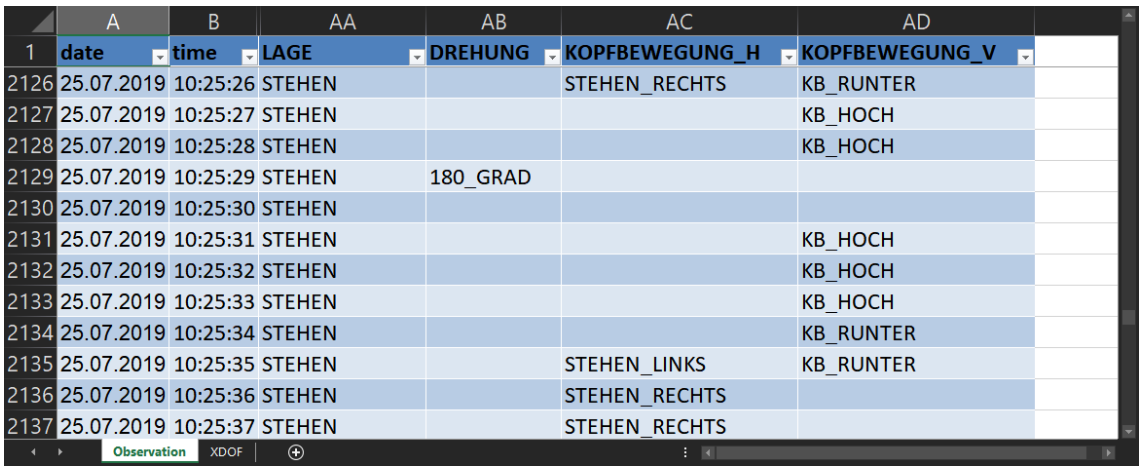

	A	B	AA	AB	AC	AD
1	date	time	LAGE	DREHUNG	KOPFBEWEGUNG_H	KOPFBEWEGUNG_V
2126	25.07.2019	10:25:26	STEHEN		STEHEN_RECHTS	KB_RUNTER
2127	25.07.2019	10:25:27	STEHEN			KB_HOCH
2128	25.07.2019	10:25:28	STEHEN			KB_HOCH
2129	25.07.2019	10:25:29	STEHEN	180_GRAD		
2130	25.07.2019	10:25:30	STEHEN			
2131	25.07.2019	10:25:31	STEHEN			KB_HOCH
2132	25.07.2019	10:25:32	STEHEN			KB_HOCH
2133	25.07.2019	10:25:33	STEHEN			KB_HOCH
2134	25.07.2019	10:25:34	STEHEN			KB_RUNTER
2135	25.07.2019	10:25:35	STEHEN		STEHEN_LINKS	KB_RUNTER
2136	25.07.2019	10:25:36	STEHEN		STEHEN_RECHTS	
2137	25.07.2019	10:25:37	STEHEN		STEHEN_RECHTS	

Observation XDOF

Abbildung 3: Beispiel eines Excel Tabellenblatts der Videoauswertung

In der fertig formatierten Exceldatei befinden sich die beobachteten Ereignisse in einer Tabelle getrennt nach den Kategorien Lage, Drehung, Kopfbewegung (vertikal) und Kopfbewegung (horizontal) (vgl. Tabellen 1 bis 4). Jedem Eintrag ist der passende Zeitpunkt zugeordnet (vgl. Abbildung 3).

4. Methode

4.1. Datenvisualisierungen

In der vorliegenden Arbeit wird sich mit der Problemstellung beschäftigt, ob es möglich ist, von den aufgezeichneten Sensordaten auf die beobachteten Ereignisse zu schließen. Zu diesem Zweck wurden zunächst verschiedene Methoden angewandt, um die vorliegenden Daten zu visualisieren und dort mögliche Zusammenhänge herauszuarbeiten. Eine statistische Auswertung ist anhand dieser Methoden jedoch nicht möglich, weshalb in Abschnitt 4.2 eine weitere Methode vorgestellt wird, die verwendet wurde, um die Daten maschinell auszuwerten. Beispiele für die in diesem Abschnitt beschriebenen Visualisierungen, finden sich in Abschnitt 5, sowie im Anhang.

4.1.1. Darstellung der Videoanalysedaten anhand numerischer Werte

Als erste mögliche Darstellungsform wurden auf Basis der Beobachtungsdaten Graphen für die verschiedenen Kategorien (Lage, Drehung im Raum, etc.) erstellt. Da es sich bei den Daten aus der Videoanalyse um kategorielle Werte handelt, wie zum Beispiel Stand, BBL, etc., musste zunächst jedem kategoriellen Wert ein numerischer Wert zugeordnet werden, um die Graphen erstellen zu können (siehe Tabellen im Anhang Abschnitt A). Jedem Beobachtungskriterium, das in Abschnitt 3.6 aufgeführt ist, ist genau eine Zahl zugeordnet. Zum Beispiel ist Kopfbewegung hoch als 1 und Kopfbewegung runter als -1 definiert. Für die Erstellung der Graphen wurden die Zeitstempel für die Werte der x-Achse und die zugeordneten numerischen Werte der Beobachtungen für die Werte der y-Achse verwendet. Diese Form der visuellen Darstellung wurde exemplarisch nur für ein Pferd erstellt, da sie sich für die Analyse deutlich schlechter verwendbar zeigte und weniger Ergebnisse lieferte, als die in Abschnitt 4.1.2 beschriebene Alternative.

4.1.2. Darstellung der X-DOF Daten in Kombination mit den zugehörigen Videoanalysedaten

Als Verbesserung zu der im vorherigen Abschnitt beschriebenen Darstellungsform wurde anschließend eine Alternative verwendet, die die gleichzeitige Darstellung der *X-DOF*-, sowie der Videoanalysedaten in einem Graphen ermöglicht. Hierzu wurde zunächst für die einzelnen Komponenten der *X-DOF* Daten (*yaw*, *pitch*, *roll*, *alt*, *dphi*) pro Pferd jeweils ein Graph erstellt. Analog zu den Graphen in Abschnitt 4.1.1 wurden für die Werte der x-Achse der Zeitstempel und die Werte der y-Achse der jeweilige Komponentenwert verwendet. Um die *X-DOF* Werte mit den Videoanalysedaten vergleichen zu können, wurde im Graph jeder Datenpunkt passend zu dem dazugehörigen Auswertungskriterium eingefärbt. Jedem Auswertungskriterium ist eine eindeutige Farbe zugeordnet. Auf diese Weise ermöglichen die Graphen eine visuelle Analyse der Daten, um mögliche Zusammenhänge zwischen den *X-DOF*- und Videodaten herauszuarbeiten. Eine Problematik dieser Darstellungsform ist, dass für jeden Sensorwert ein eigener Graph erstellt werden muss und in der Auswertung die gleichzeitige Beachtung aller Sensorwerte somit erheblich erschwert wird.

4.1.3. t-distributed stochastic neighbor embedding

Da die Sensordaten aus mehr als 3 Dimensionen bestehen, ist eine Visualisierung aller Komponente in einer Grafik nicht ohne Bearbeitung der Daten möglich.

Der Algorithmus *t-distributed stochastic neighbor embedding* (abg. *t-SNE*) wurde von Maaten und Hinton (2008) entwickelt, um hochdimensionale Daten anschaulich zu visualisieren. Hierzu werden die Daten durch die Anwendung des Algorithmus auf 2 oder 3 Dimensionen reduziert und Datenpunkte mit ähnlichen Eigenschaften gruppiert (ebd.). Somit lassen sich durch das Visualisieren transformierter Daten, Strukturen in Datensätzen lokalisieren und möglicherweise Eigenschaften herausarbeiten. Zur Visualisierung der verwendeten Sensordaten wurden diese zunächst auf 2 Dimensionen reduziert, anschließend in einem 2-dimensionalen Koordinatensystem geplottet und die Datenpunkte auf

Basis ihres Wertes, zum Beispiel Stand, BBL, etc., eingefärbt. Da bei dieser Methode die Komponente der Zeit nicht berücksichtigt wird, können die Datenpunkte aller Pferde in einem Plot dargestellt werden. Das heißt für diese Methode musste pro Kategorie nur ein einzelne Grafik erstellt werden.

4.2. Maschinelles Lernen

Die in Abschnitten 4.1.1 und 4.1.2 beschriebenen Methoden ermöglichen es, ausschließlich visuell potentielle Zusammenhänge zwischen den X-DOF und Videodaten herauszuarbeiten. Um mögliche Zusammenhänge anhand der Daten direkt zu analysieren, wurde im Anschluss eine Methode des maschinellen Lernens angewandt, die in den folgenden Abschnitten detailliert erläutert wird.

Die der vorliegenden Arbeit zugrundeliegende Problemstellung, ob es möglich ist, von den aufgezeichneten Sensordaten auf zugehörige Ereignisse zu schließen, lässt sich allgemein wie folgt beschreiben: „Gegeben ist ein Objekt mit gewissen Eigenschaften X, und gesucht ist eine Zielgröße Y“ (Richter 2019, S. 2). Mit ebendieser Problemstellung beschäftigt sich überwachtes Lernen, ein Teilgebiet des maschinellen Lernens, und wurde aus diesem Grund für die Auswertung der Daten als Grundlage gewählt. Im Bereich des maschinellen Lernens werden die vorliegenden Eigenschaften X als Featurevektor und die Zielgröße Y als Label bezeichnet. Die einzelnen Komponenten des Featurevektors werden als Features bezeichnet (ebd., S. 2). In der vorliegenden Arbeit ist das Label Y Element der Menge der beobachteten Ereignisse. Eine solche Problemstellung wird als Klassifikationsproblem und die Elemente der zuvor genannten Menge werden als Klassen bezeichnet. Es beschäftigt sich also mit dem Finden der einem Featurevektor zugehörigen Klasse (ebd., S. 2). Für die Analyse wurde ein neuronales Netz modelliert, wobei es sich um eine Methode des überwachten Lernens handelt. Das neuronale Netz wurde von Benedikt Nichell entwickelt und zur Verfügung gestellt. Zudem unterstütze er bei Verständnisfragen, sowie bei der Erstellung des Abschnitts 4.2. Dieses neuronale Netz wurde mit einem Teil

der Daten trainiert und mit den restlichen Daten kontrolliert. Das Modell wurde in der Programmiersprache Python[3] entwickelt. In den folgenden Abschnitten wird die Erstellung des neuronalen Netzes detailliert erläutert.

4.2.1. Vorbereitung der Daten

Um die Sensor- und die Beobachtungsdaten für das Training des Modells nutzen zu können, müssen zu Beginn die Daten aus den Exceldateien im Programmcode eingelesen und für das Training des Modells vorbereitet werden.

Die Sensor- und die Beobachtungsdaten werden auf Basis ihres Zeitstempels zusammengeführt. Wie in Abschnitt 3.3 erwähnt, existiert ein signifikanter Drift für die Messwerte der *Höhe*. In der vorliegenden Arbeit wird zur Vereinfachung angenommen, dass es sich bei diesem Drift um einen linearen Trend handelt. Um diesen Drift zu korrigieren, wird der lineare Trend innerhalb einer Messreihe entfernt. Das Entfernen des linearen Trends soll weniger fehlerbehaftete Sensorwerte simulieren. Aus diesem Grund wird der Trend separat pro Messreihe entfernt und nicht die selbe Funktion für alle Messreihen verwendet. Ob es sich bei den beobachteten Drifts tatsächlich um lineare Trends handelt, bleibt zu prüfen.

In einem nächsten Schritt werden von *yaw*, *pitch*, *roll* und *alt* die Delta-Werte zwischen zwei Datenpunkten berechnet und als zusätzliche Features ergänzt.

Anschließend werden alle Datenpunkte entfernt, in denen *stat* einen Wert kleiner Zwei besitzt, da diese, wie in Abschnitt 3.3 erwähnt, nicht verwendbar sind.

4.2.2. Erstellung der Training- und Testdatensätze

Für das Training des neuronalen Netzes werden auf Basis der vorbereiteten Daten (vgl. Abschnitt 4.2.1) Training- und Testdatensätze erstellt. Das Erstellen der Datensätze geschieht getrennt nach den vier betrachteten Kategorien Lage, Drehung, Kopfbewegung (vertikal) und Kopfbewegung (horizontal). Für jede der Kategorien werden mehrere Training- und

[3] Download sowie Dokumentation der Programmiersprache Python sind zu finden unter `https://www.python.org/`.

Testdatensatzkombinationen erzeugt. Die Daten eines Patienten werden jeweils als Testdatensatz verwendet und die der restlichen Patienten dienen als Trainingsdatensatz. Diese Kombination von Trainings- und Testdatensatz wird für jeden Patienten erstellt. Somit ist die Summe der Trainings-, sowie der Testdatensätze, pro Kategorie gleich der Anzahl der Patienten, für die Datensätze existieren.

Der Trainings-, sowie der Testdatensatz werden im Folgenden für das Training des neuronalen Netzes optimiert. Hierzu werden die Datensätze mithilfe verschiedener Vorprozessoren transformiert. Für die spätere Verwendung wurden die Daten skaliert, sowie mithilfe des Verfahrens der *Hauptkomponentenanalyse* in der Dimension reduziert. Diese Verfahren werden in der Arbeit nicht weiter erläutert.

In einem letzten Schritt werden Datenreihen aus den transformierten Daten erstellt. Da es sich bei den Beobachtungen um dynamische Bewegungen handelt, sind einzelne Datenpunkte weniger geeignet um die vorkommende Bewegung zu ermitteln, als Datenreihen bestehend aus mehreren aufeinander folgenden Datenpunkten. Die erstellten Datenreihen enthalten aufeinanderfolgende Datenpunkte, die sich innerhalb eines Zeitraums von fünf Sekunden befinden. Jeder dieser Datenreihen wird die Klasse zugeordnet, die am häufigsten innerhalb der jeweiligen Datenreihe auftritt. Befindet sich der Patient während der Datenreihe beispielsweise für zwei Datenpunkte in Seitenlage und wechselt in den letzten drei Datenpunkten in die Brust-Bauch-Lage, erhält diese Datenreihe die Klasse Brust-Bauch-Lage.

4.2.3. Aufbau des neuronalen Netzes

Ein neuronales Netz bildet anschaulich die Signalübertragung von Nervenzellen nach (Richter 2019, S. 221). Jedes neuronale Netz besteht aus einem Netz künstlicher Neuronen, die untereinander verbunden sind. Eine Gruppe von Neuronen, die sich auf einer Ebene befinden, wird als Schicht (engl. *layer*) bezeichnet. Ein neuronales Netz besteht generell aus einer Eingangs- und Ausgangsschicht (engl. *input* und *output layer*), die mit einer beliebigen Anzahl von versteckten Schichten (engl. *hidden layer*) miteinander verbunden

sind (Richter 2019, S. 226 f.). Die Verarbeitung von Daten geschieht in einem neuronalen Netz, indem die Daten der Eingabeschicht übergeben, diese von den Neuronen der verschiedenen Schichten verarbeitetet und abschließen von der letzten Schicht nach der Verarbeitung ausgegeben werden. Innerhalb des neuronale Netzes reagieren Neuronen auf den Dateneingang über ihre jeweilige *Aktivierung*. Hierunter versteht man die Datenverarbeitung des Dateneingangs mit einer sogenannten *Aktivierungsfunktion*, die dem Neuron zugeordnet ist (ebd., S. 225). Die *Aktivierungsfunktion* berechnet für den Eingangswert einen Ausgabewert, der an die verbundenen Neuronen weitergegeben wird. Auf die in dem entwickelten Modell genutzten *Aktivierungsfunktionen* wird im Folgenden nicht weiter eingegangen.

Ein neuronales Netz muss, bevor es Daten auswerten kann, mit Trainingsdatensätzen trainiert werden. Hierfür werden dem neuronalen Netz Trainingsdaten mit den dazugehörenden Labels übergeben und das neuronale Netz lernt auf Basis dieser Referenzdaten, um bei unbekannten Datensätzen die passende Klasse für die jeweiligen Testdatensätze zurückgeben zu können. Um die Trainingsperformance überwachen zu können, wird ein bestimmter Prozentsatz der Trainingsdaten als Validierungsdatensatz verwendet. Die Performance wird gemessen, indem die Klassen für den Validierungsdatensatz nach jedem Trainingsschritt mithilfe des neuronalen Netzes prognostiziert und mit den tatsächlichen Klassen verglichen werden. Für das Training des entwickelten Modells wurden 10 Prozent der Trainingsdaten als Validierungsdatensatz verwendet.

Das für diese Arbeit entwickelte Model besteht aus einer Eingangsschicht, die mit einer *Long Short-Term Memory* Schicht verbunden ist. Die *LSTM* Schicht ist eingebettet in einen *Bidirectional* Block. An diese Schicht sind abwechselnd zwei *Dense* und *Dropout* Schichten angebunden. Zuletzt werden die Daten über einen weiteren *Dense* Schicht ausgegeben.

Die *LSTM* Schicht ist die entscheidendste Schicht für die Verarbeitung der Datenreihen. Ihr Design erlaubt es Informationen über eine längere (*L* von *LSTM*) Zeit speichern und so ein Kurzeitgedächtnis aufzubauen. Auf diese Weise können bereits beobachtete Werte bei späteren Entscheidungen mit einbezogen und aus Fehlentscheidungen gelernt werden

(Hochreiter und Schmidhuber 1997, S. 1). Ein *LSTM* Netz ist aus diesem Grund gut dafür geeignet, auf Basis von Datenreihen trainiert zu werden, da es nicht nur den aktuellen Datenpunkt berücksichtigt, sondern auch die bereits verarbeiteten. Die Einbettung der LSTM Schicht in einen *Bidirectional* Block führt dazu, dass die Datenreihen nicht nur von einer LSTM Schicht verarbeitet werden, sondern zusätzlich von einer zweiten, die die Datenreihen von der anderen Richtung aus verarbeitet.

Die anderen Schichten werden hier nicht weiter erläutert, da sie keine Relevanz für das Verständnis des Models besitzen.

5. Ergebnisse

In den folgenden Abschnitten werden Ergebnisse aus den Datenvisualisierungen gesammelt, die trainierten neuronalen Netze evaluiert, sowie die für das Training verwendeten Daten ausgewertet. Für die Hypothese relevante Ergebnisse werden zudem dargelegt und diskutiert.

Die Ergebnisse für die Kategorie Lage sind im Vergleich zu den anderen Kategorien deutlich vielversprechender. Dies könnte dadurch bedingt sein, dass es sich um die einzige Kategorie handelt, für die alle Datenpunkte klassifiziert werden konnten. Für die Kategorien Kopfbewegung (vertikal) und Kopfbewegung (horizontal) beispielsweise, können nur Datenpunkte klassifiziert werden, bei denen sich die vertikale, bzw. horizontale Lage des Kopfes verändert. Im folgenden wird daher ausschließlich die Kategorie Lage ausführlich besprochen. Ergebnisse der anderen Kategorien werden allenfalls angerissen und finden sich ergänzend im Anhang.

5.1. Auswertung der Datenvisualisierungen

5.1.1. Darstellung der Videoanalysedaten anhand numerischer Werte

Im Folgenden werden Grafiken der in Abschnitt 4.1.1 beschriebenen Darstellungsform exemplarisch anhand eines Pferdes ausgewertet. Ein Vergleich der Graphen der Videoanalysedaten mit den Graphen der Sensordaten stellt sich bei dieser Methode als schwierig dar, da ein Graph mit Videoanalysedaten parallel mit 5 verschiedenen Graphen mit Sensordaten verglichen werden muss. Hierbei muss darauf geachtet werden, dass man ausschließlich zusammengehörende Werte vergleicht, das heißt Werte, die den selben Zeitstempel besitzen. Als Beispiel vergleiche Abbildung 4, in der **Pferd 5** mit zugehörigen Graphen der Sensordaten vergleichen wird. Für den korrekten Vergleich wurde darauf geachtet, dass die selben Zeitstempel exakt untereinander liegen.

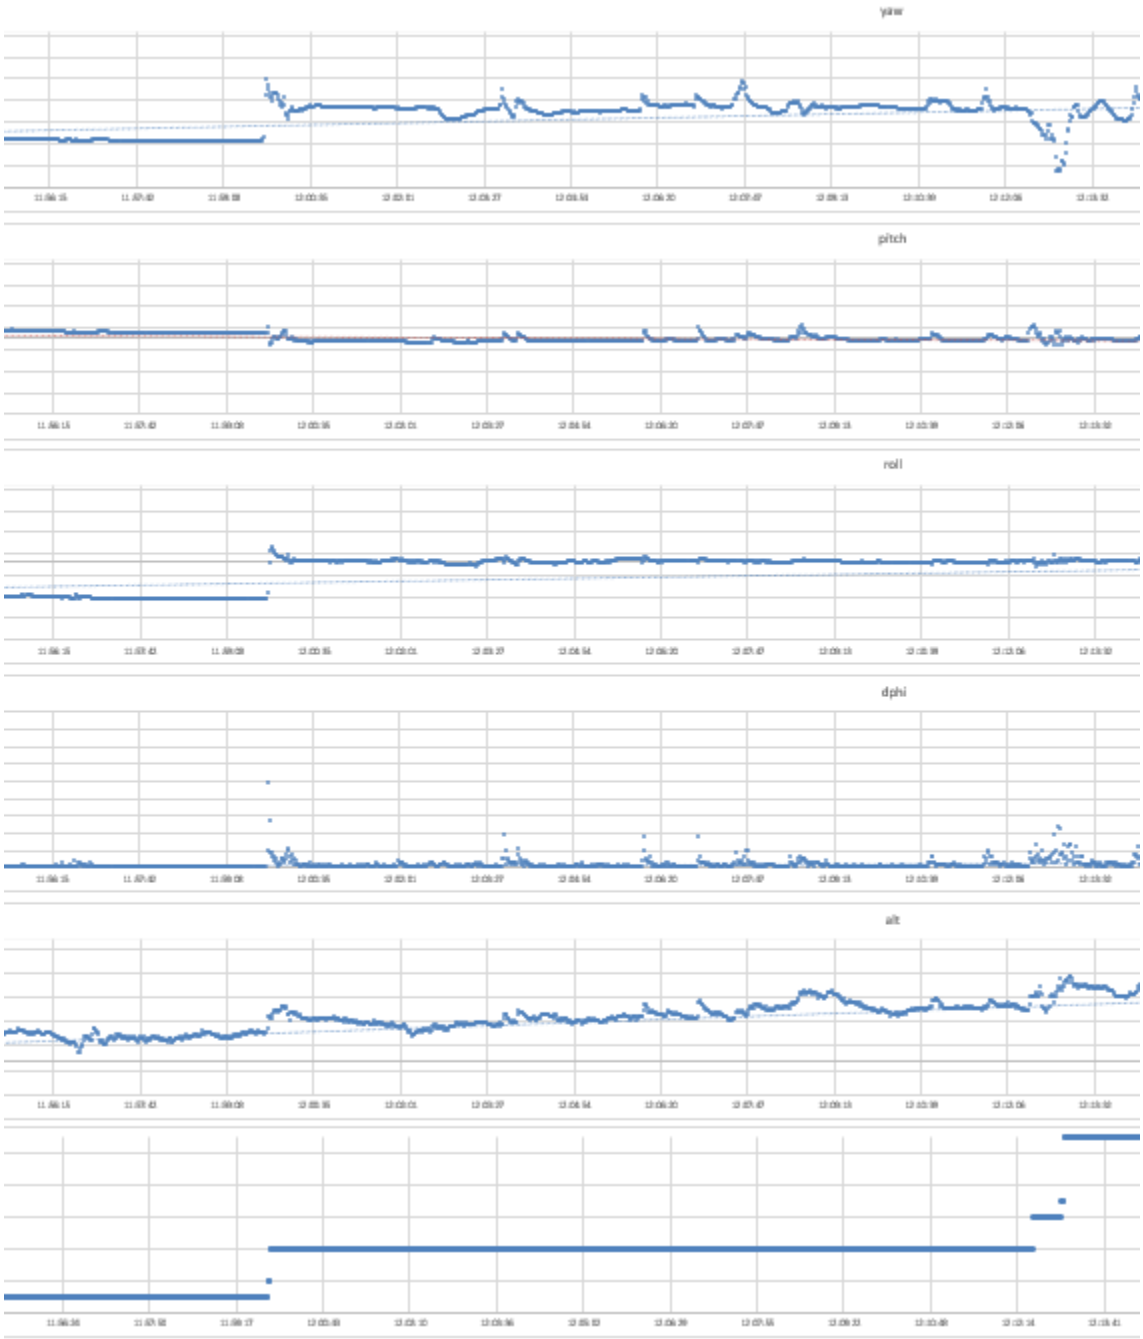

Abbildung 4: Ausschnitt von Graphen zu allen Sensorwerten und dem Graphen zu Kategorie Lage.
Reihenfolge von oben nach unten: *yaw*, *pitch*, *roll*, *dphi*, *alt*, *Lage*. Auftretende Werte für *Lage* von links nach rechts: *Seitenlage*, *Ansatz BBL*, *BBL*, *Ansatz bis Vorderextremitäten gestreckt*, *Beine gestreckt*, *Stand*

Es wäre möglich alle Sensordaten, sowie die Daten der Videoanalyse in einem Koordinatensystem darzustellen. Dies ist jedoch keine geeignete Lösung für die beschriebene Problematik, da die Zusammenführung mehrerer Graphen in einem Koordinatensystem die Übersichtlichkeit signifikant verschlechtern würde.

Die Ergebnisse, die sich mit dieser Methode herausarbeiten lassen, sind identisch zu den Analyseergebnissen aus der in Abschnitt 4.1.2 beschriebenen Darstellungsform. Da die, auf Basis dieser Methode erstellen Graphen deutlich übersichtlicher sind und den Vergleich der Sensorwerte und Videoanalysedaten vereinfachen, werden die Ergebnisse der Auswertung im folgenden Abschnitt 5.1.2 besprochen.

Aufgrund der großen Anzahl der Abbildungen finden sich im Anhang exemplarisch ausschließlich die Graphen für **Pferd 5**.

5.1.2. Darstellung der X-DOF Daten in Kombination mit den zugehörigen Videoanalysedaten

Die in Abschnitt 4.1.2 beschriebenen Graphen erleichtern die Analyse der Sensor- und Videoanalysedaten deutlich, da die Graphen zu den Sensorwerte im Gegensatz zu der im vorigen Abschnitt 5.1.1 betrachteten Graphen, bereits die Informationen aus der Videoanalyse enthalten. Das heißt, es müssen für die Videoanalysedaten keine separaten Graphen erstellt werden.

Anhand der Farbe der Datenpunkte erkennt man direkt welche Klasse zu welchem Datenpunkt gehört, ohne das bei den erzeugten Graphen die Übersichtlichkeit verschlechtert wird, da keine zusätzlichen Punkte in den Koordinatensystemen ergänzt werden.

In Abbildung 5 sieht man exemplarisch für Pferd **Pferd 3** die Graphen bezüglich der Kategorie Lage.

Die hier betrachteten und am häufigsten vorkommenden Klassen besitzen in der Abbildung die folgenden Farben: Seitenlage hellblau, BBL dunkelblau und Stehen hellgrün. Visuell kann die Klasse Seitenlage sehr gut von den Klassen BBL und Stehen getrennt werden. Bei der Klasse Seitenlage sind alle Sensorwerte, ausgenommen die Werte der Höhe,

Abbildung 5: Ausschnitt von Graphen zu allen Sensorwerten, eingefärbt für Lage. Reihenfolge von oben nach unten: *alt*, *dphi*, *pitch*, *roll*, *yaw*. Farbzuordnung: Seitenlage - hellblau, BBL - dunkelblau, Stehen - hellgrün, Ansatz bis Vorderextremitäten gestreckt - dunkelgrün, Umlagerung - lachsfarben, Hundesitzige Stellung - rot. Abfolge der Ereignisse: Seitenlage > kurz BBL > Stehen > ging wieder zu Boden in BBL > endgültiges Stehen

relativ konstant, während sie bei den anderen beiden Klassen eine höhere Varianz besitzen. Die Schwankungen in der Höhe lassen sich über den in Abschnitt 3.3 beschriebenen Drift erklären. Dies könnte darauf hindeuten, dass das Pferd in Seitenlage ruhig liegt, sich also wenig bis gar nicht bewegt. Zudem existiert bei dem Übergang von der Klasse Seitenlage zu Klasse BBL ein deutlicher Sprung in den Sensorwerten der alt, pitch, roll und yaw. Der Sprung bei den Höhewerten erklärt sich darüber, dass sich während des Aufrichtens die Höhe des Kopfes und somit des Sensors signifikant verändert. Die Änderung des pitch Wertes lässt sich darüber erklären, dass es nicht unwahrscheinlich ist, dass sich die Neigung des Kopfes, die sich während des Liegens wenig bis gar nicht geändert hat, während des Aufrichtens deutlich mehr variiert und zunächst in eine andere Ausrichtung ”springt”. Bei roll springen die Werte in dem betrachteten Beispiel von etwa 90 Grad auf Werte nahe 0 Grad. Dies deutet darauf hin, dass das Pferd in Seitenlage den Kopf auf dem Boden abgelegt hatte und ihn während des Aufrichtens parallel zum Boden ausrichtet, also in die physiologisch Kopfhaltung beim Stehen bringt. Eine Änderung von yaw während des Aufstehens ist ebenfalls nicht verwunderlich, da es nicht unwahrscheinlich ist, dass sich das Pferd während des Aufstehens geringfügig oder mehr dreht, alleine schon durch das Aufrichten des Kopfes ändert sich der yaw Wert ein wenig.

Bei den Klassen BBL und Stehen lassen sich ebenfalls unterschiedliche Strukturen in den Sensordaten erkennen, diese sind allerdings weniger trennscharf, so dass es schwer ist, dies auf explizite Faktoren zu fixieren.

Bei den Kategorien Kopfbewegung (vertikal), sowie Kopfbewegung (horizontal) lassen sich Zusammenhänge zu spezifischen Sensorwerten erkennen, die im Folgenden erläutert werden. Die zugehörigen Graphen finden sich in Abbildungen 6 and 7 von **Pferd 5**.

Die Klassen in den Abbildungen besitzen folgende Farbzuordnung:

- Kopfbewegung (horizontal): BBL rechts - dunkelblau, BBL links - hellgrün, Stehen rechts - dunkelgrün, Stehen links - lachsfarben.

- Kopfbewegung (vertikal): Kopfbewegung hoch - dunkelblau, Kopfbewegung runter -

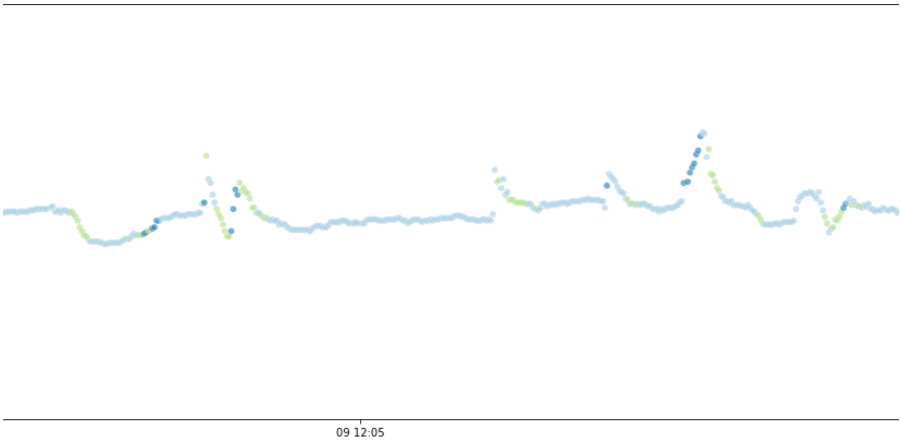

Abbildung 6: Ausschnitt von Graph zu yaw Werten, eingefärbt für Kopfbewegung (horizontal)
Farbzuordnung: BBL rechts - dunkelblau, BBL links - hellgrün, Stehen rechts - dunkelgrün, Stehen links - lachsfarben

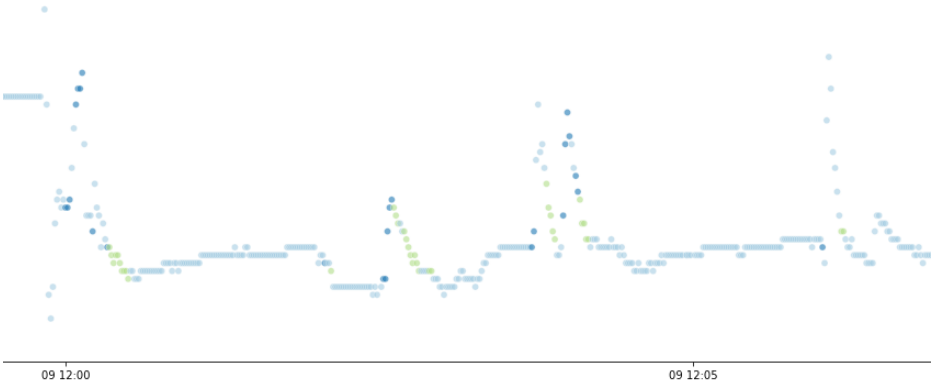

Abbildung 7: Ausschnitt von Graph zu pitch Werten, eingefärbt für Kopfbewegung (vertikal)
Farbzuordnung: Kopfbewegung (vertikal): Kopfbewegung hoch dunkelblau, Kopfbewegung runter hellgrün.

hellgrün.

Zunächst fällt auf, dass anders als bei Graphen der Kategorie Lage, viele Punkte farblich keiner Klasse zugeordnet sind, da das Pferd nicht zu jedem Zeitpunkt eine relevante Kopfbewegung ausführte.

Bei den Graphen zu den *yaw*-Werten lässt sich deutlich ein Zusammenhang zu den Klassen der Kategorie Kopfbewegung (horizontal) erkennen. Dies lässt sich damit erklären, dass sich der Wert yaw ändert, sobald sich der Sensor um die Hochachse dreht, d.h. wenn sich der Kopf nach rechts bzw. links bewegt. Dies lässt jedoch keinen direkten Rückschluss auf den Auslöser der Kopfbewegung zu, da sich der Kopf auch nach rechts bzw. links bewegt, wenn sich der gesamte Körper des Pferdes um die Hochachse dreht, ohne dass sich die Ausrichtung des Hals ändert. Dies erklärt auch, dass sich in dem Graphen keine Äquivalenzbeziehung erkennen lässt, nur eine deutliche Korrelation.

Analog lässt sich der Zusammenhang zwischen den *pitch*-Werten und den Klassen der Kategorie Kopfbewegung (vertikal) erklären. Die Sensorwerte ändern sich in diesem Fall wenn sich der Kopf hebt bzw. senkt, was durch das Heben bzw. Senken des Kopfes oder durch das Aufstehen bzw. Setzen des Pferdes ausgelöst werden kann. Ein ähnlicher Zusammenhang lässt sich auch zu den Werten von *alt* erkennen. Hierfür gilt die selbe Erklärung.

Aufgrund der großen Anzahl an Abbildungen finden sich im Anhang für alle Pferde exemplarisch ausschließlich die Graphen für die Kategorie Lage.

5.1.3. t-distributed stochastic neighbor embedding

In diesem Abschnitt werden exemplarisch durch *t-SNE* reduzierten Sensordaten ausgewertet. In Abbildung 8 findet sich der Plot der Werte, die auf Basis der Kategorie *Lage* eingefärbt wurden.

Wie eindeutig in der Abbildung zu erkennen ist, wurden die Daten am häufigsten mit Seitenlage (hellblau), Brust-Bauch-Lage (hellgrün) und Stehen (lachsfarben) klassifiziert.

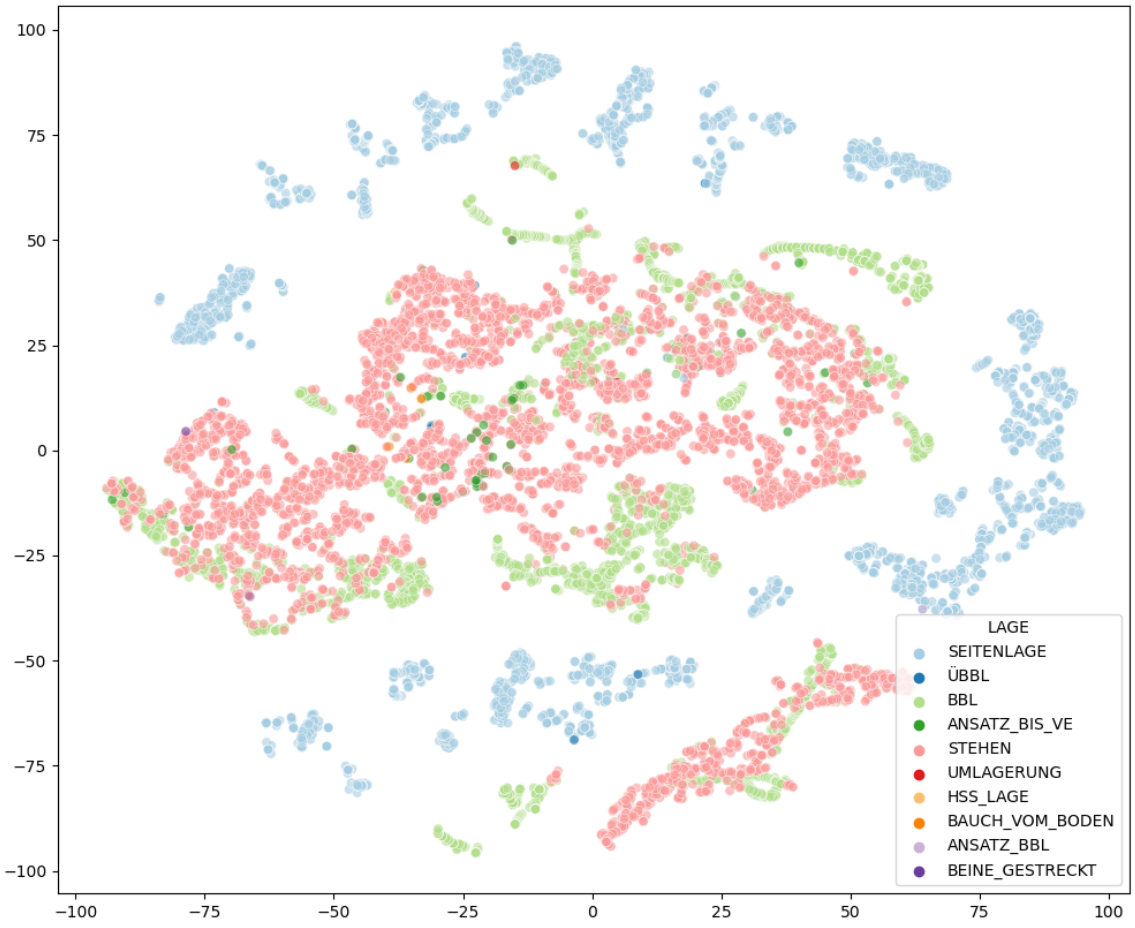

Abbildung 8: Sensordaten reduziert durch t-SNE, mit Klassifizierung für Lage

Die Datenpunkte, die zu der Klasse Seitenlage gehören, sind deutlich abgetrennt von den den Datenpunkten der Klassen Brust-Bauch-Lage und Stehen. Sie befinden sich allerdings nicht in einer einzelnen Wolke, dies ist möglicherweise ein Hinweis darauf, dass diese Klasse in verschiedene Klassen unterteilt werden könnte. Die Datenpunkte der Klassen Brust-Bauch-Lage und Stehen, sind nicht so deutlich voneinander abgegrenzt, was darauf hindeuten könnte, dass Informationen für die Bestimmung der Klasse in den Sensordaten fehlen oder Ungenauigkeiten, wie zum Beispiel der fehlerhafte Wert für die Höhe, zu verfälschten Ergebnissen führen. Der Algorithmus beachtet allerdings keinen zeitlichen Verlauf, daher bleibt zu betrachten, wie die Ergebnisse des trainierten Modells sind, das diesen berücksichtigt.

5.2. Maschinelles Lernen

5.2.1. Korrelationsmatrix

Verfahren des maschinellen Lernens profitieren im Allgemeinen von stochastisch unabhängigen Features (Richter 2019, S. 315). Mithilfe einer *Korrelationsmatrix* lässt sich die paarweiße Korrelation mehrere Features visuell übersichtlich darstellen. Ein Elemente ρ_{ij} der Korrelationsmatrix gibt die Korrelation der Komponenten x_i und x_j eines Featurevektors an. Nimmt ρ_{ij} den Wert 0 an, sind die zwei Komponenten x_i und x_j stochastisch unabhängig. Bei einem Wert von 1, bzw. -1, sind sie vollständig positiv, bzw. vollständig negativ, korreliert.

In Abbildung 9 ist die Korrelationsmatrix der für das Training verwendeten Features dargestellt. Die Elemente ρ_{ii} auf der Hauptdiagonalen der Korrelationsmatrix, geben die Korrelation eines Features x_i mit sich selbst an, was auch den erklärt, dass diese immer den Wert 1 annehmen. Wie in der Abbildung zu sehen ist, existiert die stärkste Korrelation zwischen den Features *dpitch* und *dalt*, den Delta Werten für *Höhe* und *pitch*, mit einem Wert von 0.47. Dies könnte auf den Zusammenhang zurückgeführt werden, dass ein Heben des Kopfes, also eine Steigerung von *pitch*, in vielen Fällen zu einer Steigerung der *Höhe*

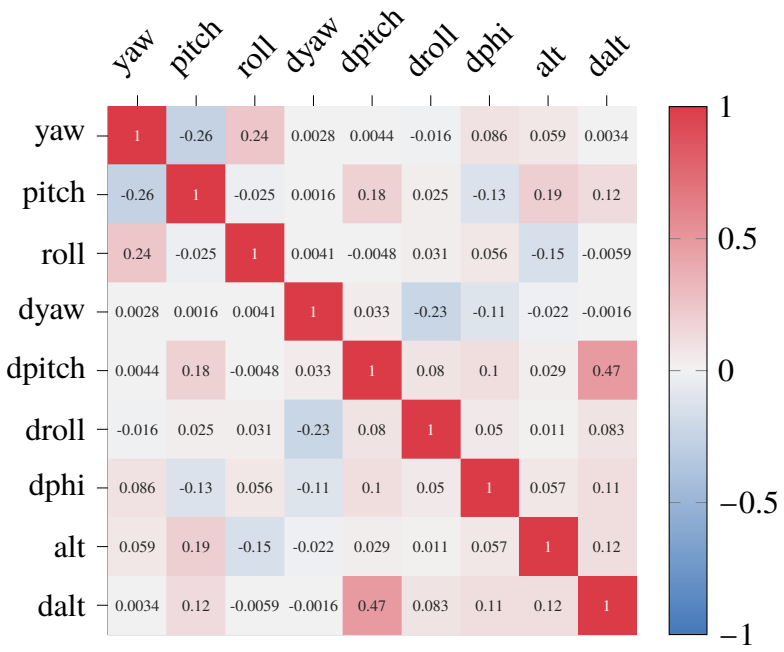

Abbildung 9: Korrelationsmatrix der verwendeten Features

führt. Aus einem positiven *dpitch* Wert folgt allerdings nicht zwangsweise eine Steigerung der *Höhe*, da sich gleichzeitig der gesamte Körper in einem stärkeren Maße absenken oder der Kopf nicht parallel zum Boden ausgerichtet sein könnte. Die nächsthöchste (negative) Korrelation besteht zwischen *yaw* und *pitch* mit einem Wert von -0.26. Die Korrelationen zwischen den restlichen Features sind entweder ähnlich stark wie zwischen *yaw* und *pitch* oder deutlich geringer.

Da die Features im Allgemeinen nicht stark korreliert sind, scheinen sie im Hinblick auf diesen Aspekt gut für den Verwendung in Verfahren des maschinellen Lernens geeignet zu sein.

5.2.2. Auswertung des trainierten neuronalen Netzes

Mithilfe einer Konfusionsmatrix lässt sich übersichtlich die Korrektheit der Voraussagen eines neuronalen Netzes darstellen. Eine Konfusionsmatrix enthält für jede vorkommende Klasse eine Zeile, sowie eine Spalte, und ist somit von der Form $n \times n$ für n Klassen. Ein

Eintrag ρ_{ij} der Konfusionsmatrix gibt an wie häufig für die tatsächliche Klasse x_i, die Klasse x_j von dem neuronalen Netz ermittelt wurde. Die Elemente ρ_{ii} auf der Hauptdiagonalen der Konfusionsmatrix geben somit die korrekten Vorhersagen an.

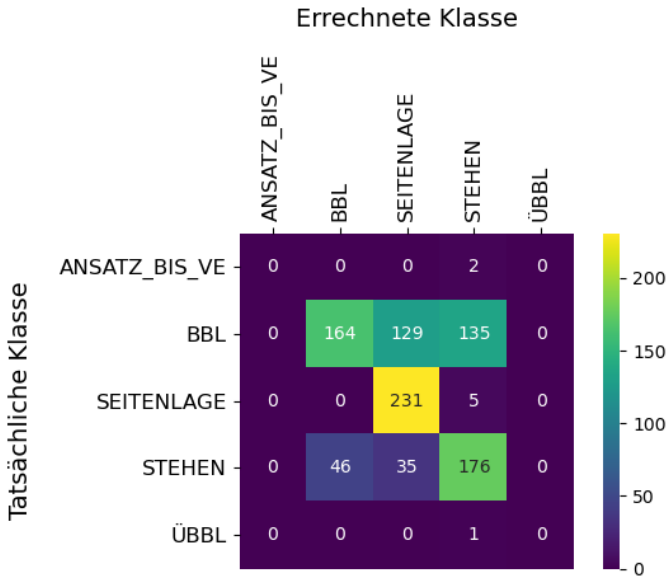

Abbildung 10: Konfusionsmatrix (Testdatensatz **Pferd 1**)

Im Folgenden werden die Ergebnisse beispielhaft für das neuronale Netz dargelegt, in dem die Daten von **Pferd 1** als Testdatensatz verwendet wurden. In Abbildung 10 findet sich die zugehörige Konfusionsmatrix. Zunächst fällt auf, dass die Klassen `BBL`, `SEITENLAGE` und `STEHEN` mit deutlichen Abstand am häufigsten vorkommen. Die Klasse `SEITENLAGE` konnte dabei fast komplett richtig zugeordnet werden. Nur für 5 (2.2%) Datenreihen der Klasse `SEITENLAGE` wurden die Klasse `STEHEN` ermittelt. Ebenfalls konnte die Klasse `STEHEN` zu einem großen Anteil (68.5%) korrekt zugeordnet werden. Die restlichen Datenreihen wurden den falschen Klassen `BBL` und `SEITENLAGE` zugeordnet. Die Klasse `BBL` konnte hingegen nur zu einem Anteil von 38.3% korrekt ermittelt werden. Insgesamt konnten für 61.8% der Datenreihen dieses Testdatensatzes die Klassen korrekt ermittelt werden.

Für die anderen Testdatensätze der Kategorie *Lage* können, mit Ausnahme von **Pferd 2**,

ähnlich gute oder bessere Ergebnisse erzielt werden. Bei **Pferd 2** konnten 33.8% der tatsächlichen Klassen korrekt ermittelt werden, bei **Pferd 3** 85.2%, bei **Pferd 4** 81% und bei **Pferd 5** 89.1%.

Für die restlichen Kategorien können die Klassen signifikant schlechter ermittelt werden. Dies ist unter anderen damit zu erklären, dass für einen Großteil der Datenreihen keine Klasse zugeordnet werden kann und sie für diese Datenreihen sozusagen eine *leere* Klasse zugeordnet bekommen. Das neuronale Netz hat somit eine große Datengrundlage zum Lernen, wann die Datenreihe nicht zu einer der Klassen der Kategorien zugeordnet werden kann, aber nur eine sehr kleine für die manuell klassifizierten Datenreihen.

6. Diskussion

Die Ergebnisse zeigen sich vielversprechend im Bezug auf die Möglichkeit ein System zu entwickeln, dass dem/der behandelnden VeterinärmedizinerIn anzeigt in welcher Lage sich das Pferd gerade befindet, bzw. welche Aktivität es derzeit ausführt. In zukünftigen Studien sollten verschiedene Aspekte analysiert und das Design des neuronalen Netzes weiterentwickelt werden, um die Trefferrate der Voraussagen des neuronalen Netzes zu erhöhen und somit den produktiven Einsatz zu ermöglichen. Im Folgenden werden potentielle Verbesserungen, sowie mögliche Umsetzungen beispielhaft dargelegt.

Wie in Abschnitt 3.3 beschrieben existiert ein deutlicher Drift in den Sensorwerten für die Höhe. Optimal wäre es, wenn der Sensor so verbessert werden könnte, dass er Werte ohne Drift zurückgibt und nur minimale Abweichungen in den Werten vorhanden sind. Sollte die Korrektheit der gemessenen Höhenwerte nicht signifikant verbessert werden können, müsste eine Hilfsfunktion entwickelt werden, die den Drift bei unbekannten Messreihen während des Schreibens der Werte ohne merkbare Latenz bereinigen kann, um diese für ein trainiertes neuronales Netz nutzen zu können.

Durch das Anbringen des Sensors *X-DOF* am Kopf des Pferdes beziehen sich die Werte auf die Lageänderung des Kopfes und es existieren keine Daten für Lageänderungen anderer Körperteile. Wie bereits in Abschnitt 3.3 erklärt, lassen die Werte keinen direkten Rückschluss auf den Grund der Lageänderung zu. Diese Problematik könnte einen negativen Einfluss auf die Qualität des Trainings des neuronalen Netzes besitzen. In weiteren Studien sollte daher untersucht werden, ob durch den Einsatz weiterer Sensoren an zusätzlichen Körperteilen des Pferdes, z.B. am Rücken des Pferdes, das Training des neuronalen Netzes verbessert und in Folge die Erkennungsrate der korrekten Klassen gesteigert werden kann. Ergänzend hierzu bietet es sich an, die Positionierung der Sensoren zu variieren und die zugehörigen Trainingsergebnisse miteinander zu vergleichen.

Die Werte des *Accelerometers*, des *Gyroskops* und des *Magnetometers* werden bereits mithilfe des *X-DOF* Sensors in *yaw*, *pitch* und *roll* umgewandelt. Aus diesem Grund kann

das neuronale Netz nicht mit den Rohdaten der Sensoren trainiert werden. Eine Möglichkeit zur Verbesserung wäre es, über den Sensor ausschließlich die Rohdaten auszugeben, diese drahtlos an einen PC zu übermitteln und auf diesem die Umwandlung durchzuführen. Dies würde ermöglichen, auch die Rohdaten für das Training zu verwenden und zusätzlich könnten auf Basis dieser weitere Features berechnet werden, um die Datengrundlage zu vergrößern. Für die Darstellung von *yaw*, *pitch* und *roll* werden *eulersche Winkel* verwendet. Um die Datengrundlage zu vergrößern, könnte man diese beispielsweise um Darstellungen der Werte durch Quaternionen oder Transformationsmatrizen erweitern.

Weiterhin sollte geprüft werden, ob die Daten vom *X-DOF* Sensor in einer höheren Abtastrate übermittelt werden können. Dies würde einerseits ermöglichen, die Anzahl der Datenpunkte innerhalb einer Datenreihe zu erhöhen und andererseits erlauben, den Zeitrahmen der Datenreihen zu verringern, ohne die Anzahl der Datenpunkte dafür verkleinern zu müssen.

Eine deutliche Erhöhung der Abtastrate würde zudem erlauben, den Typ des *Convolutional Neural Network* einzusetzen. Dieser wird vorrangig zur Auswertung von Video- und Audioauswertung eingesetzt, da es mit diesem möglich ist, automatisch Features aus diesen Daten während des Trainings zu extrahieren. Auch im Bereich der Aktivitätserkennung auf Basis von Sensordaten wurden *Convolutional Neural Networks* in einigen aktuellen Studien erfolgreich eingesetzt und somit sind sie auch für den hier untersuchten Einsatzbereich interessant (Ha und Choi 2016; Cruciani u. a. 2020, vgl. u.a.). Da hierfür mehrere aufeinanderfolgende Datenpunkte als eine Klasse ausgewertet werden, müsste die Datenrate deutlich höher sein, als sie es aktuell ist.

Mithilfe von *t-SNE* (siehe Abschnitt 5.1.3) konnte veranschaulicht werden, dass bestimmte Klassen in den zur Verfügung stehenden Datensätzen signifikant häufiger aufgetreten sind. Somit existierte für diese Klassen eine deutlich größere Lerngrundlage. Jedoch existieren selbst für die häufig vorkommenden Klassen nicht sehr viele Datenreihen als Datengrundlage. Dies könnte auch die in Abschnitt 5.2.2 erwähnten falschen Vorhersagen erklären. Das Erstellen weiterer Datensätze von verschiedenen Pferden wäre eine Möglichkeit das

Training des neuronalen Netzes zu verbessern. Das Ergebnis in Abschnitt 5.1.3 deutete zudem darauf hin, dass die Klassen Brust-Bauch-Lage und Stehen nicht deutlich voneinander zu trennen sind und dass es möglich sein könnte, verschiedene Klassen zu unterteilen. Wie bereits in dem Abschnitt erwähnt, könnte dies mit dem fehlerbehafteten Höhenwert oder der fehlende Berücksichtigung des zeitlichen Ablaufes zusammenhängen. Daher sollte in weiteren Studien überprüft werden, ob die Trainingsergebnisse durch weitere Anpassungen der Klassen verbessert werden können. Beispielsweise wäre vorstellbar, dass eine Unterscheidung zwischen sicherem und unsicherem Stand sinnvoll sein könnte oder verschiedene selten vorkommende Klassen in einer neuen Klasse zusammengeführt werden könnten.

Um das neuronale Netz sinnvoll für die Überwachung der postoperativen Aufwachphase von Pferden nutzen zu können, sollte zudem überprüft werden, ob die gewählten Klassen für diesen Zweck geeignet sind. Eventuell könnten die Klassen auch unter diesem Aspekt angepasst werden. Eine Möglichkeit wäre, die Verwendung der Klassen `UNKRITISCH` und `KRITISCH`, um das neuronale Netz darauf zu trainieren, ob sich das Pferd gerade in einer kritischen Situation befindet. Hierfür müsste zunächst untersucht werden, ob und wie dies beobachtbar ist.

Abschließend kann festgehalten werden, dass die Ergebnisse der Arbeit die untersuchte Hypothese bestätigen. Es ist möglich ein neuronales Netz so zu trainieren, dass es verwertbare Aussagen über die Lagen des Pferdekörpers in der Aufwachbox treffen kann. Somit könnte ein trainiertes neuronales Netz dafür eingesetzt werden, um die postoperativen Aufwachphase von Pferden nach durchgeführter Allgemeinanästhesie zu überwachen. Das neuronale Netz könnte simultan Rückmeldungen geben, welche Bewegungen das Pferd derzeit ausführt und die/der behandelnden VeterinärmedizinerIn bräuchte keinen speziellen Vorkenntnisse um komplizierte Sensordaten o.ä. auszuwerten. Ein weiterer Vorteil wäre der Zeitgewinn, da die Ergebnisse unmittelbar vorliegen würden.

7. Zusammenfassung

In der vorliegenden Arbeit, wurde im Rahmen einer Pilotstudie an der Veterinärmedizinischen Universität Wien untersucht, ob es einen Zusammenhang zwischen Sensordaten (*X-DOF*) und durch Videoanalyse gewonnene Bewegungsdaten der postoperativen Aufwachphase nach durchgeführter Allgemeinanästhesie gibt. Der Sensor *X-DOF* besteht aus den Sensoren *Accelerometer*, *Gyroskop*, *Magnetometer* und *Barometer* und liefert Werte für *yaw*, *pitch*, *roll*, *delta Phi* und die *Höhe*. Anhand des Ablaufs einer postoperativen Aufwachphase wurde ein Kriterienkatalog für die Auswertung der Videodaten erstellt. Kriterien wurden für die vier Kategorien Lage, Drehung, Kopfbewegung (vertikal) und Kopfbewegung (horizontal) erstellt. Die Videos wurden mithilfe von den Computerprogrammen Solomon Coder und BORIS sekundengenau ausgewertet und die Daten anschließend in einer Exceldatei exportiert. Diese Auswertung wurde für fünf verschiedene Pferde durchgeführt. Mögliche Zusammenhänge zwischen den Sensor- und den Videodaten wurden anhand verschiedener Datenvisualisierungen herausgearbeitet. Zur anschließenden Analyse wurde ein neuronales Netz auf Basis eines Teils dieser Daten trainiert und anschließend mit den übrigen Daten überprüft. Insgesamt konnten für die Kategorie Lage bei **Pferd 1** 61.8% der tatsächlichen Klassen korrekt ermittelt werden, bei **Pferd 2** 33.8%, bei **Pferd 3** 85.2%, bei **Pferd 4** 81% und bei **Pferd 5** 89.1%. Für die anderen Kategorien konnten deutlich schlechtere Ergebnisse erzielt werden, weshalb in der Arbeit der Fokus auf die Kategorie Lage gelegt wurde. Die Ergebnisse des Trainings des neuronalen Netzes sind vielversprechend und deuten darauf hin, dass ein auf Basis von Sensordaten trainiertes neuronales Netz dafür eingesetzt werden kann, die zugehörigen Bewegungen oder Aktivitäten treffend zu ermitteln. Somit könnten VeterinärmedizinerInnen maschinell dabei unterstützt werden, die postoperativen Aufwachphase nach durchgeführter Allgemeinanästhesie zu Überwachen und kritische Situationen zeitnah zu erkennen. Damit könnte ein Beitrag geleistet werden, die Mortalitätsrate bei Pferden während der Aufwachphase nach einer durchgeführten Allgemeinanästhesie signifikant zu verringern.

8. Extended summary

Monitoring of the horses' recovery phase

Comparison of a video analysis with measurements of the orientation and height

In the present thesis, a pilot study was conducted at the University of Veterinary Medicine Vienna to investigate whether there is a correlation between sensor data (*X-DOF*) and movement data obtained by video analysis of the postoperative recovery phase after performed general anesthesia. The sensor *X-DOF* consists of the sensors *accelerometer*, *gyroscope*, *magnetometer* and *barometer* and provides values for *yaw*, *pitch*, *roll*, *delta Phi* and *altitude*. Based on the course of a postoperative recovery phase, a criteria catalog for the evaluation of the video data was created. Criteria were created for the four categories position, rotation, head movement (vertical) and Head movement (horizontal). The videos were analyzed to the second using the computer programs Solomon Coder and BORIS. Afterwards the data was exported to an Excel file. This analysis was performed for five different horses. Possible correlations between the sensor data and the video data were reviewed using various data visualizations. For subsequent analysis, a neural network was trained on the basis of part of this data and then tested on the remaining data. Overall, 61.8% of the actual classes could be correctly determined for the category position for **horse 1**, for **horse 2** 33.8%, for **horse 3** 85.2%, for **horse 4** 81% and for **horse 5** 89.1%. Significantly worse results were achieved for the remaining categories, which is why in the thesis the focus was put on the category position. The results of the neural network training are promising and indicate, that a neural network trained on the basis of sensor data can be used for the purpose, to accurately determine the movements or activities associated to the sensor data. Therefore, veterinarians could be assisted by neural networks trained to monitor the postoperative recovery phase after general anesthesia and which could then be used to recognize critical situations in a timely manner.

Literatur

Bidwell, Lori A., Larry R. Bramlage und William A. Rood (Jan. 2007). „Equine perioperative fatalities associated with general anaesthesia at a private practice – a retrospective case series“. In: *Veterinary Anaesthesia and Analgesia* 34.1, S. 23–30. ISSN: 1467-2987. DOI: 10.1111/j.1467-2995.2005.00283.x. URL: https://doi.org/10.1111/j.1467-2995.2005.00283.x.

Brodbelt, Dave (2009). „Perioperative mortality in small animal anaesthesia“. In: *The Veterinary Journal* 182.2, S. 152–161. ISSN: 1090-0233. DOI: https://doi.org/10.1016/j.tvjl.2008.06.011. URL: http://www.sciencedirect.com/science/article/pii/S1090023308002256.

Cruciani, Federico u. a. (März 2020). „Feature learning for Human Activity Recognition using Convolutional Neural Networks“. In: *CCF Transactions on Pervasive Computing and Interaction* 2.1, S. 18–32. ISSN: 2524-5228. DOI: 10.1007/s42486-020-00026-2. URL: https://doi.org/10.1007/s42486-020-00026-2.

Dugdale, Alexandra HA und Polly M. Taylor (Mai 2016). „Equine anaesthesia-associated mortality: where are we now?“ In: *Veterinary Anaesthesia and Analgesia* 43.3, S. 242–255. ISSN: 1467-2987. DOI: 10.1111/vaa.12372. URL: https://doi.org/10.1111/vaa.12372.

Eerdekens, Anniek u. a. (2020). „Automatic equine activity detection by convolutional neural networks using accelerometer data“. In: *Computers and Electronics in Agriculture* 168, S. 105139. ISSN: 0168-1699. DOI: https://doi.org/10.1016/j.compag.2019.105139. URL: http://www.sciencedirect.com/science/article/pii/S0168169919319283.

Fries, M., S. Montavon, C. Spadavecchia und O. L. Levionnois (2017). „Evaluation of a wireless activity monitoring system to quantify locomotor activity in horses in experimental settings“. In: *Equine Veterinary Journal* 49.2, S. 225–231. DOI: https://doi.org/10.1111/evj.12568. eprint: https://beva.onlinelibrary.wiley.com/doi/pdf/10.1111/evj.12568. URL: https://beva.onlinelibrary.wiley.com/doi/abs/10.1111/evj.12568.

Gottschalk, André, Hugo Van Aken, Michael Zenz und Thomas Standl (2011). „Ist Anästhesie gefährlich?“ In: *Dtsch Arztebl International* 108.27, S. 469–474. DOI: 10.3238/arztebl.2011.0469. eprint: https://www.aerzteblatt.de/pdf.asp?id=96293. URL: https://www.aerzteblatt.de/int/article.asp?id=96293.

Ha, Sojeong und Seungjin Choi (2016). „Convolutional neural networks for human activity recognition using multiple accelerometer and gyroscope sensors“. In: *2016 International Joint Conference on Neural Networks (IJCNN)*, S. 381–388. DOI: 10.1109/IJCNN.2016.7727224.

Hochreiter, Sepp und Jürgen Schmidhuber (1997). „Long Short-Term Memory“. In: *Neural Computation* 9.8, S. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735. URL: https://doi.org/10.1162/neco.1997.9.8.1735.

Maaten, Laurens van der und Geoffrey Hinton (2008). „Visualizing Data using t-SNE“. In: *Journal of Machine Learning Research* 9.86, S. 2579–2605. URL: http://jmlr.org/papers/v9/vandermaaten08a.html.

Maisonpierre, I. N. u. a. (Apr. 2019). „Accelerometer activity tracking in horses and the effect of pasture management on time budget“. In: *Equine Veterinary Journal* 51.6, S. 840–845. DOI: https://doi.org/10.1111/evj.13130. eprint: https://beva.onlinelibrary.wiley.com/doi/pdf/10.1111/evj.13130. URL: https://beva.onlinelibrary.wiley.com/doi/abs/10.1111/evj.13130.

Richter, Stefan (2019). *Statistisches und maschinelles Lernen. Gängige Verfahren im Überblick*. Springer Berlin Heidelberg. ISBN: 9783662593547. DOI: 10.1007/978-3-662-59354-7. URL: https://doi.org/10.1007%2F978-3-662-59354-7.

Wagner, Ann E. (2008). „Complications in Equine Anesthesia“. In: *Veterinary Clinics of North America: Equine Practice* 24.3. Surgical Complications and Management Strategies, S. 735–752. ISSN: 0749-0739. DOI: https://doi.org/10.1016/j.cveq.2008.10.002. URL: http://www.sciencedirect.com/science/article/pii/S0749073908000564.

Young, S. S. und Polly M. Taylor (1993). „Factors influencing the outcome of equine anaesthesia: a review of 1,314 cases“. In: *Equine Veterinary Journal* 25.2, S. 147–151. DOI: https://doi.org/10.1111/j.2042-3306.1993.tb02926.x. eprint: https://beva.onlinelibrary.wiley.com/doi/pdf/10.1111/j.2042-3306.1993.tb02926.x. URL: https://beva.onlinelibrary.wiley.com/doi/abs/10.1111/j.2042-3306.1993.tb02926.x.

A. Zuordnungen von Auswertungskriterien zu numerischen Werten

Tabelle 5: Zuordnungen der Kategorie Lage zu numerischen Werten

Kategorie	numerischer Wert
Seitenlage	1
Ansatz Brust-Bauch-Lage	2
Übergang Brust-Bauch-Lage	3
Brust-Bauch-Lage	4
Bauch vom Boden abgehoben	5
Ansatz bis Vorderextremitäten gestreckt	6
Beine gestreckt	7
Hundesitzige Stellung	8
Umlagerung auf andere Seite	9
Robben durch die Box	10
Stehen auf allen vier Gliedmaßen	11

Tabelle 6: Zuordnungen der Kategorie Drehung im Raum zu numerischen Werten

Kategorie	numerischer Wert
0 Grad	0
90 Grad	1
180 Grad	2
270 Grad	3

Tabelle 7: Zuordnungen der Kategorie Kopfbewegung (vertikal) zu numerischen Werten

Kategorie	numerischer Wert
Kopfbewegung hoch	1
Kopfbewegung runter	-1

Tabelle 8: Zuordnungen der Kategorie Kopfbewegung (horizontal) zu numerischen Werten

Kategorie	numerischer Wert
Seitenlage Kopfbewegung rechts	1
Seitenlage Kopfbewegung links	-1
Brust-Bauch-Lage Kopfbewegung rechts	2
Brust-Bauch-Lage Kopfbewegung links	-2
Stehen Kopfbewegung rechts	3
Stehen Kopfbewegung links	-3

B. Originale Sensordaten inklusive angepasster Wert für alt

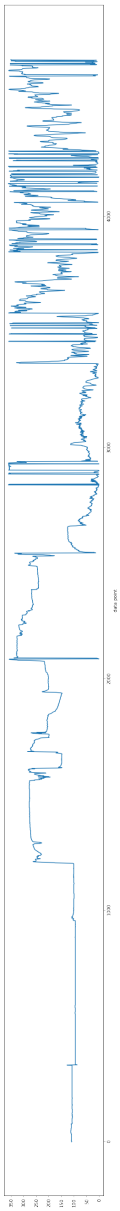

Abbildung 11: **Pferd 1** — Werte für *yaw*

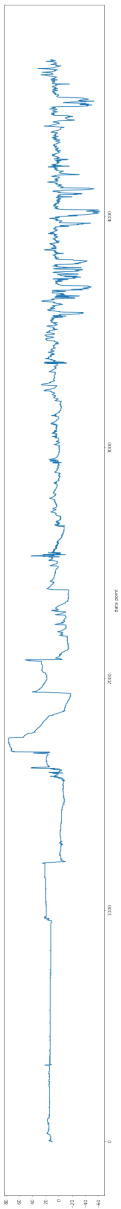

Abbildung 12: **Pferd 1** — Werte für *pitch*

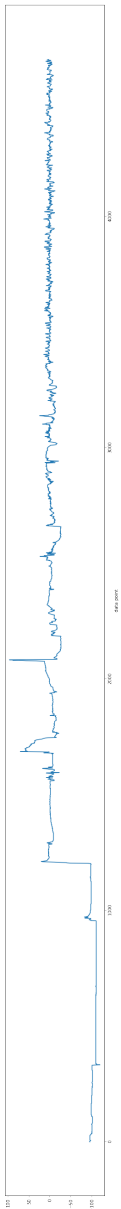

Abbildung 13: **Pferd 1** — Werte für *roll*

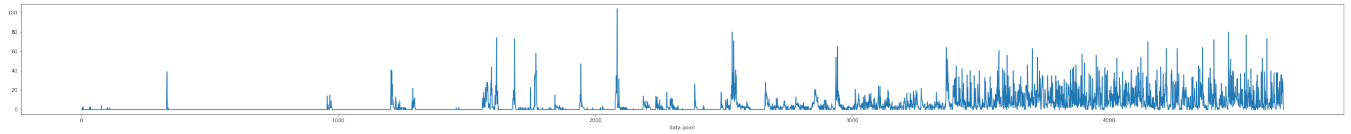

Abbildung 14: **Pferd 1** — Werte für *dphi*

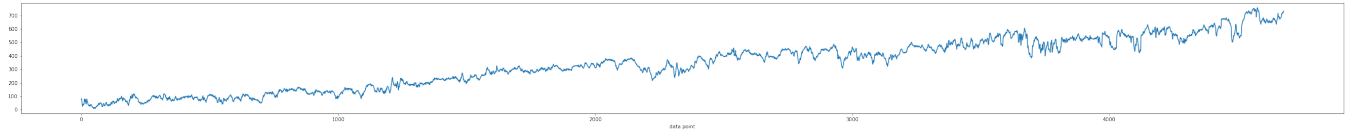

Abbildung 15: **Pferd 1** — Werte für *alt*

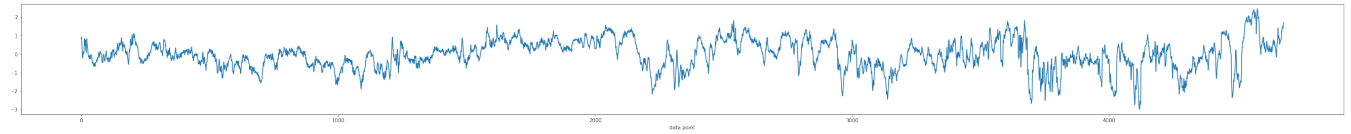

Abbildung 16: **Pferd 1** — angepasste Werte für *alt*

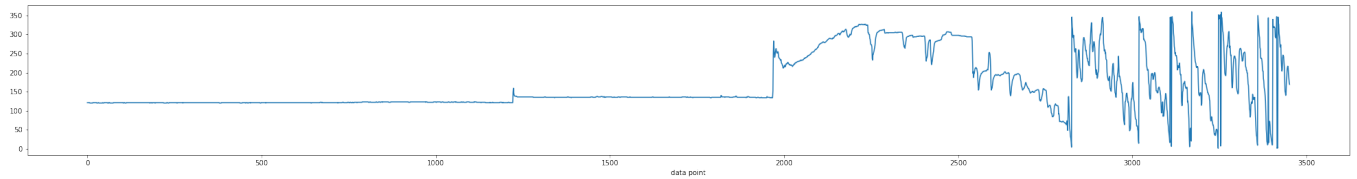

Abbildung 17: **Pferd 2** — Werte für *yaw*

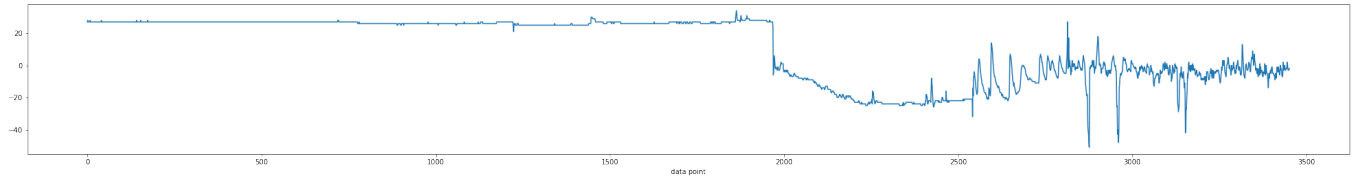

Abbildung 18: **Pferd 2** — Werte für *pitch*

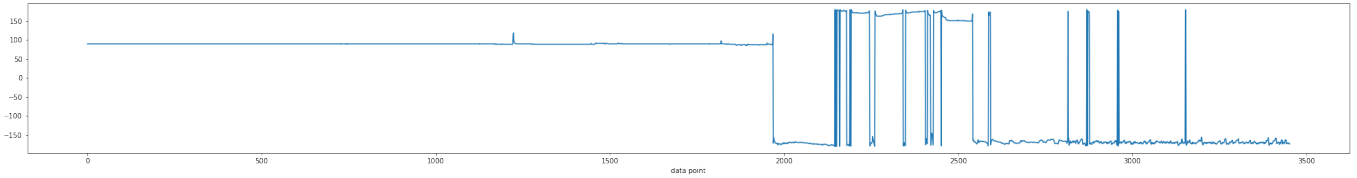

Abbildung 19: **Pferd 2** — Werte für *roll*

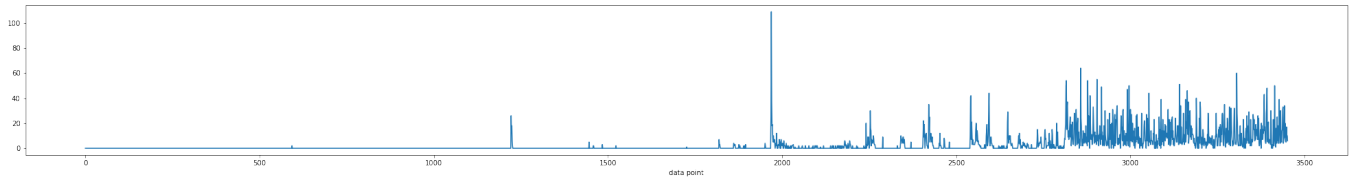

Abbildung 20: **Pferd 2** — Werte für *dphi*

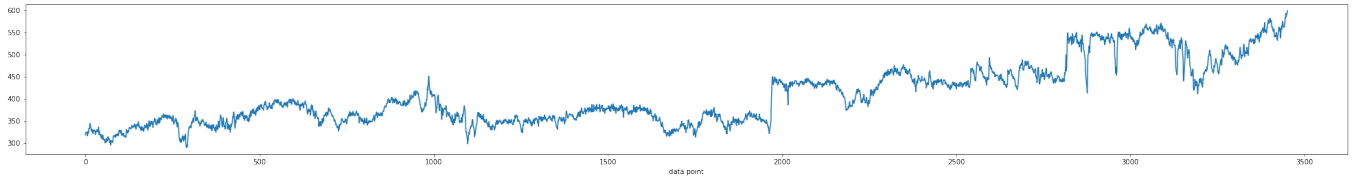

Abbildung 21: **Pferd 2** — Werte für *alt*

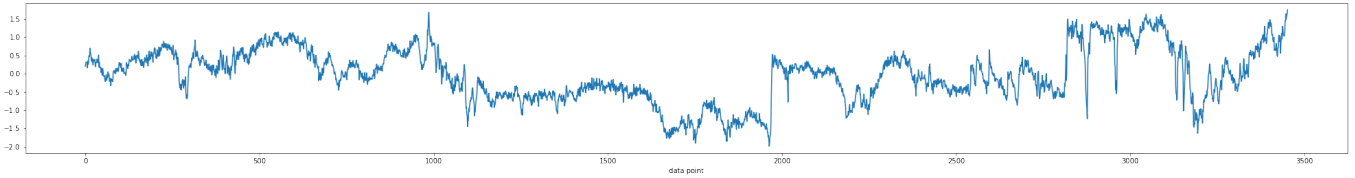

Abbildung 22: **Pferd 2** — angepasste Werte für *alt*

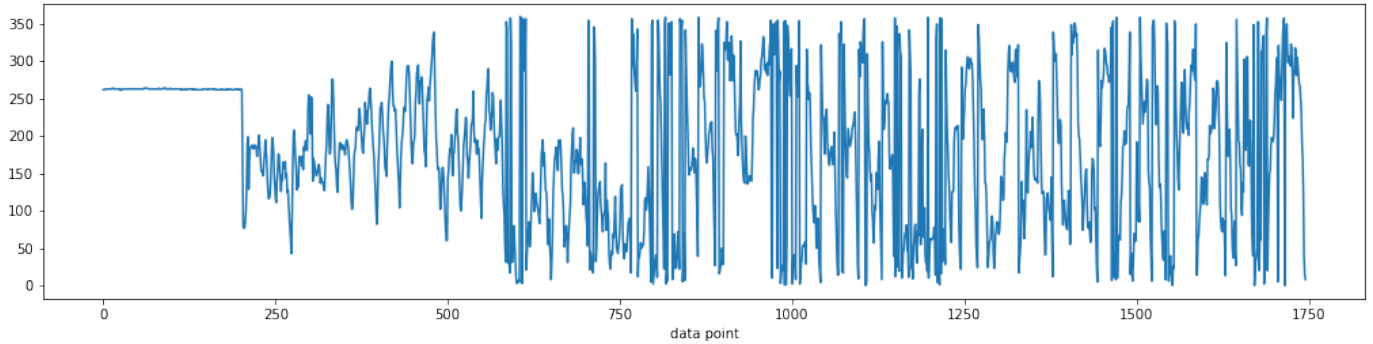

Abbildung 23: **Pferd 3** — Werte für *yaw*

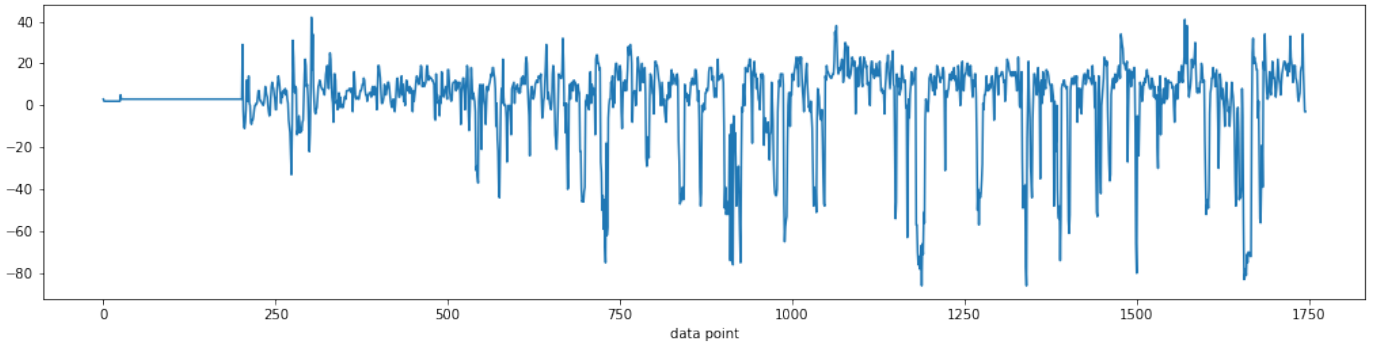

Abbildung 24: **Pferd 3** — Werte für *pitch*

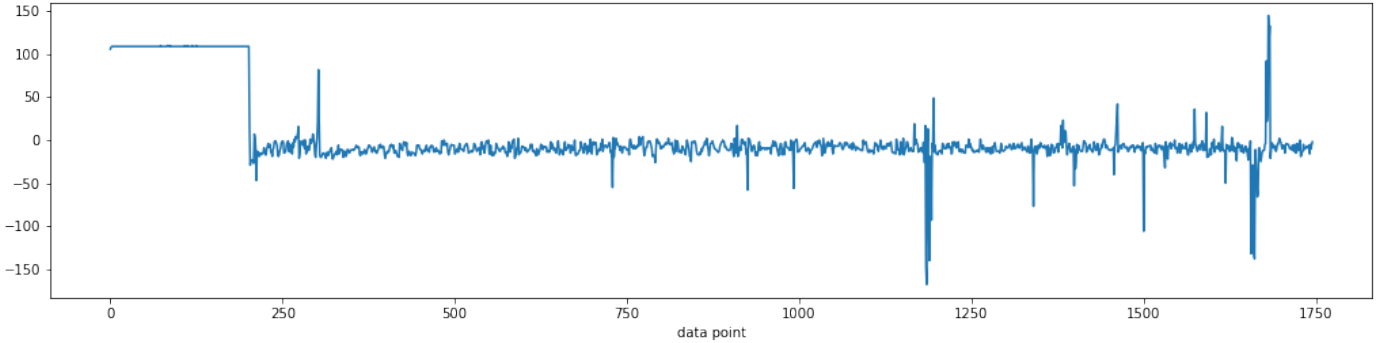

Abbildung 25: **Pferd 3** — Werte für *roll*

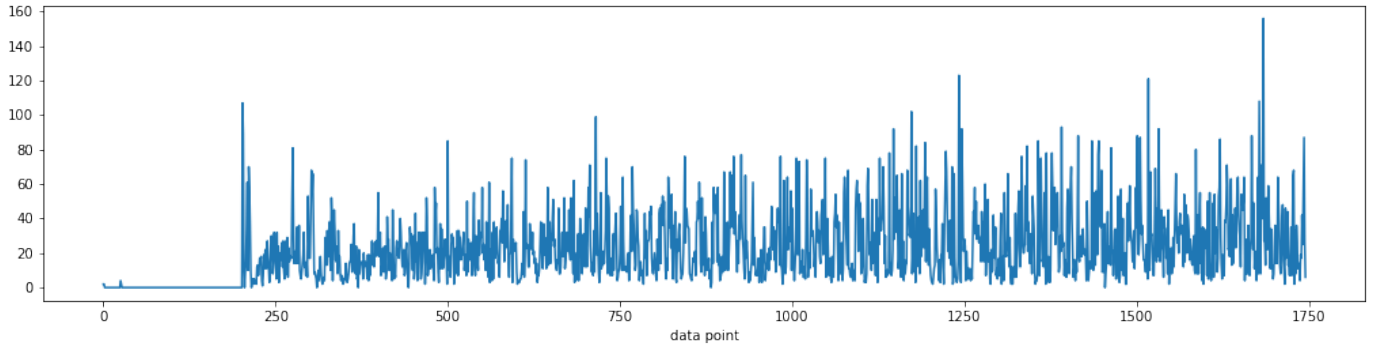

Abbildung 26: **Pferd 3** — Werte für *dphi*

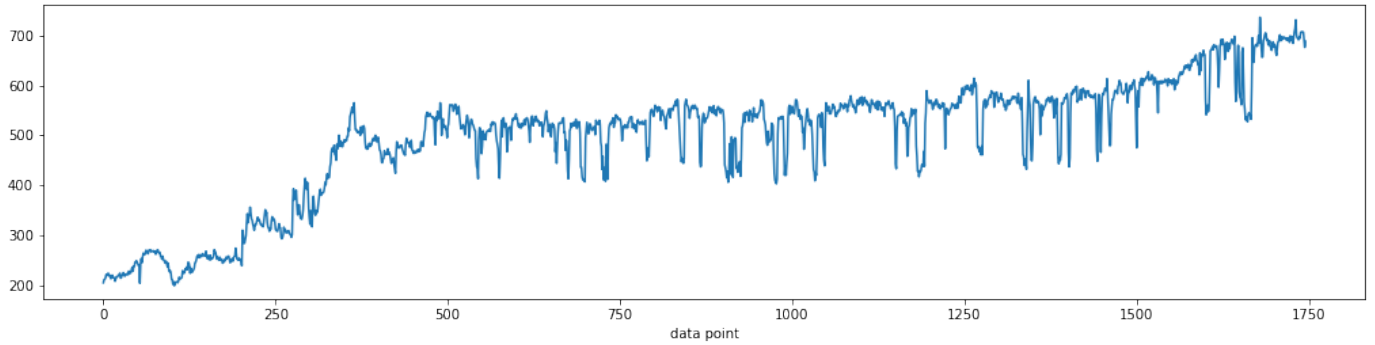

Abbildung 27: **Pferd 3** — Werte für *alt*

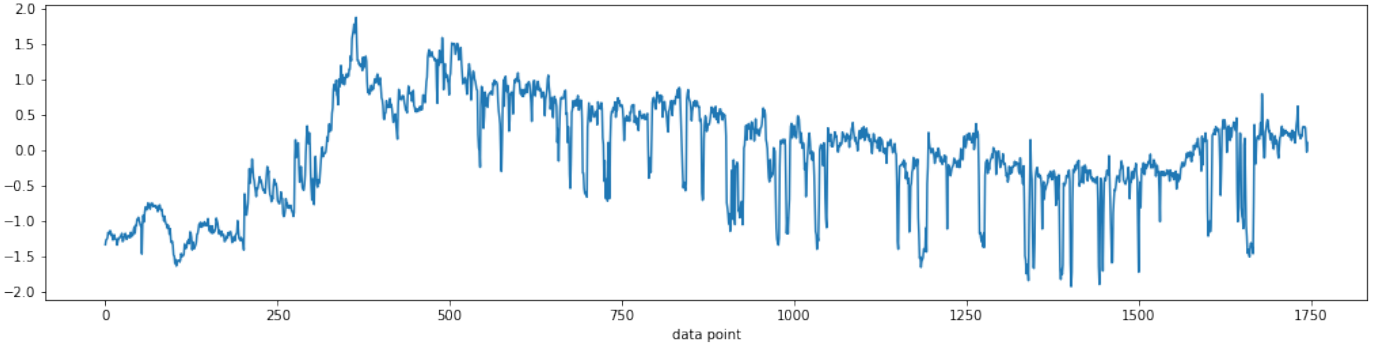

Abbildung 28: **Pferd 3** — angepasste Werte für *alt*

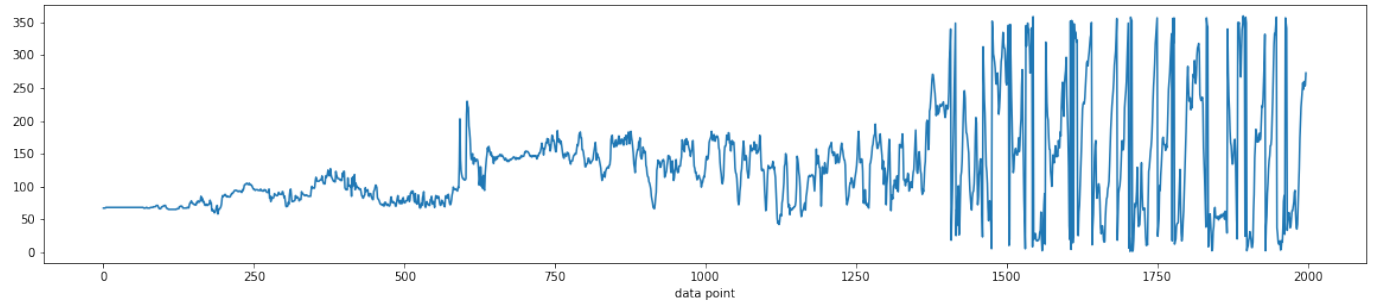

Abbildung 29: **Pferd 4** — Werte für *yaw*

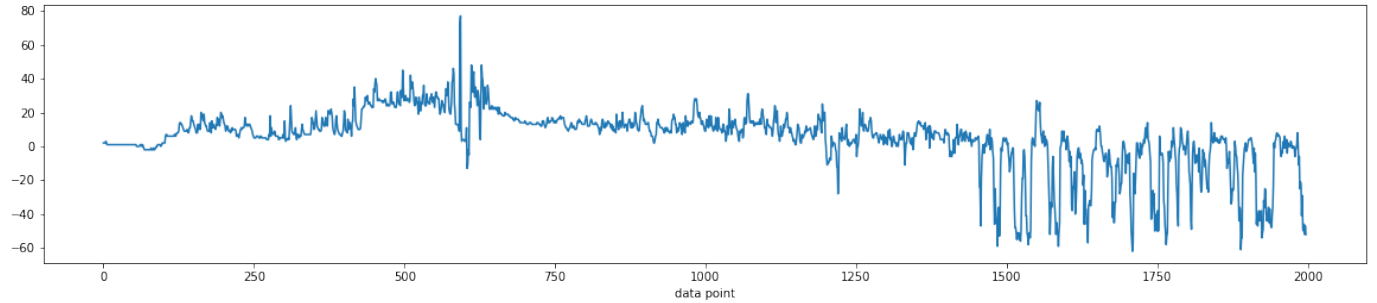

Abbildung 30: **Pferd 4** — Werte für *pitch*

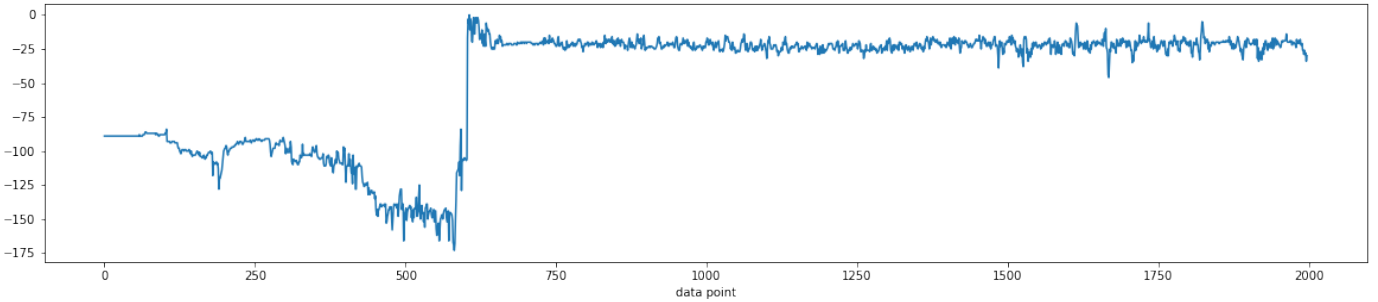

Abbildung 31: **Pferd 4** — Werte für *roll*

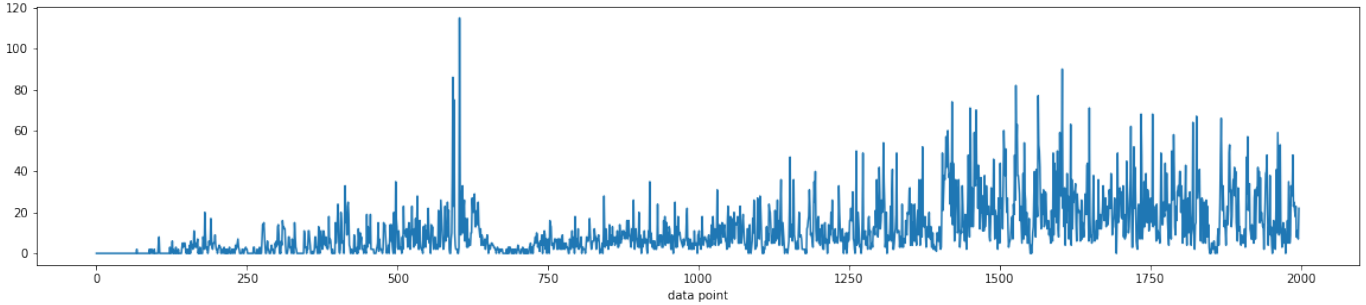

Abbildung 32: **Pferd 4** — Werte für *dphi*

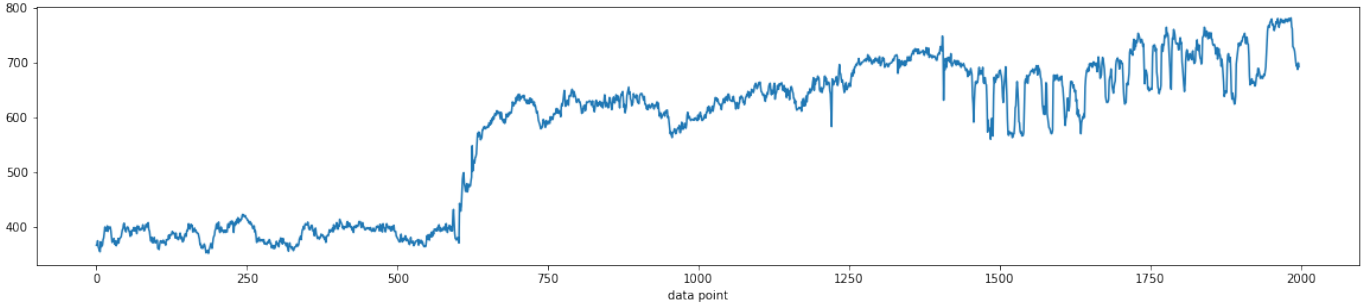

Abbildung 33: **Pferd 4** — Werte für *alt*

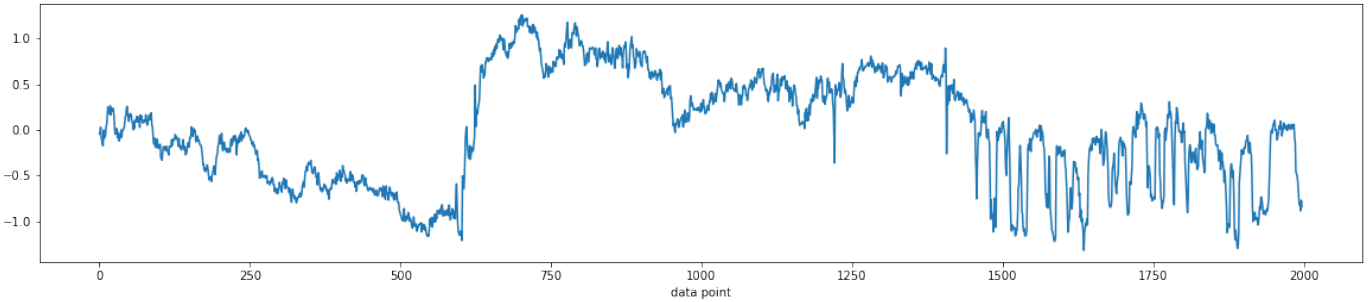

Abbildung 34: **Pferd 4** — angepasste Werte für *alt*

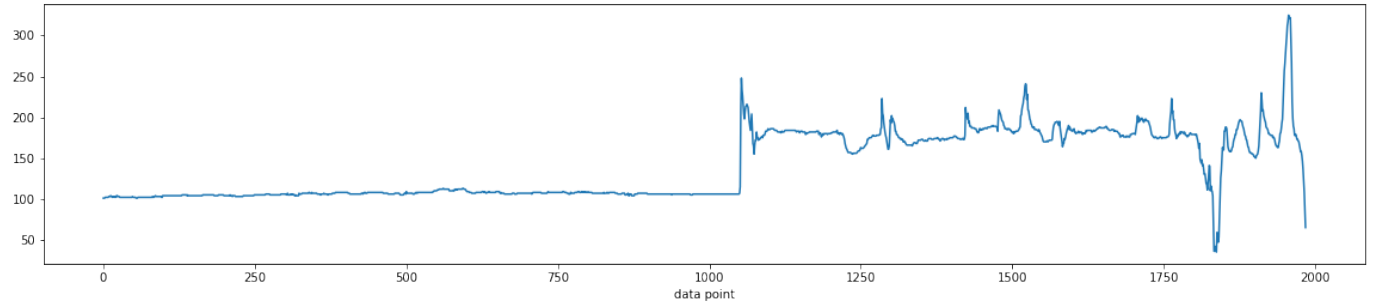

Abbildung 35: **Pferd 5** — Werte für *yaw*

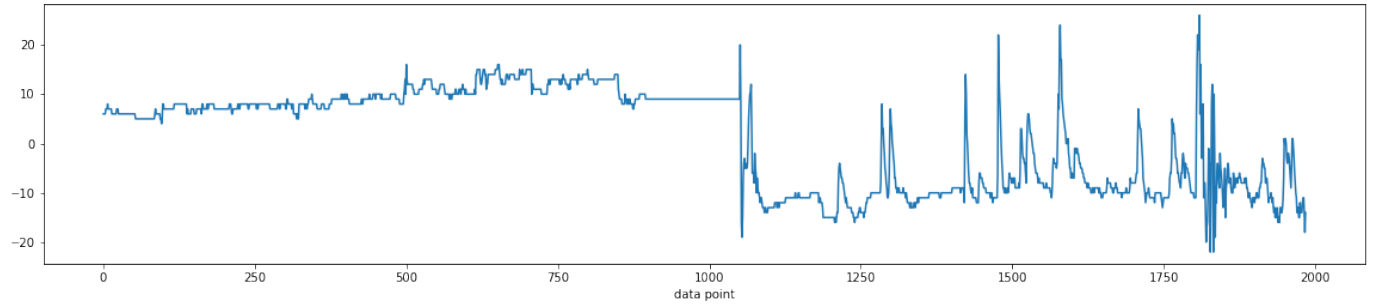

Abbildung 36: **Pferd 5** — Werte für *pitch*

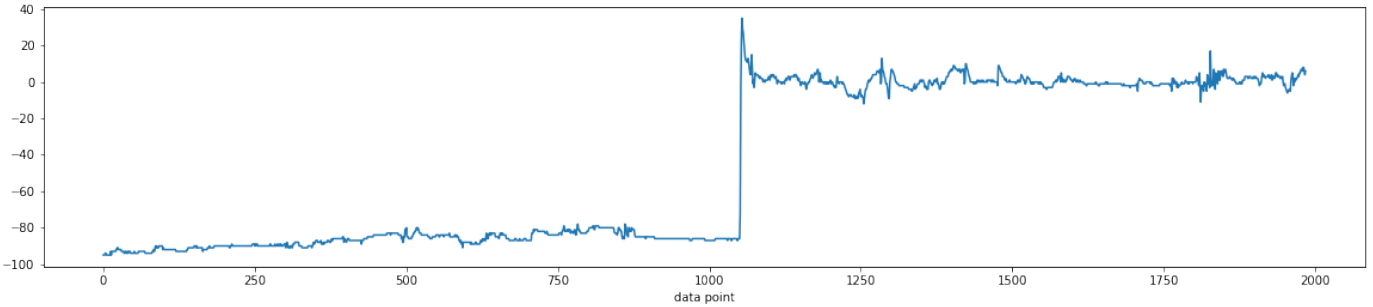

Abbildung 37: **Pferd 5** — Werte für *roll*

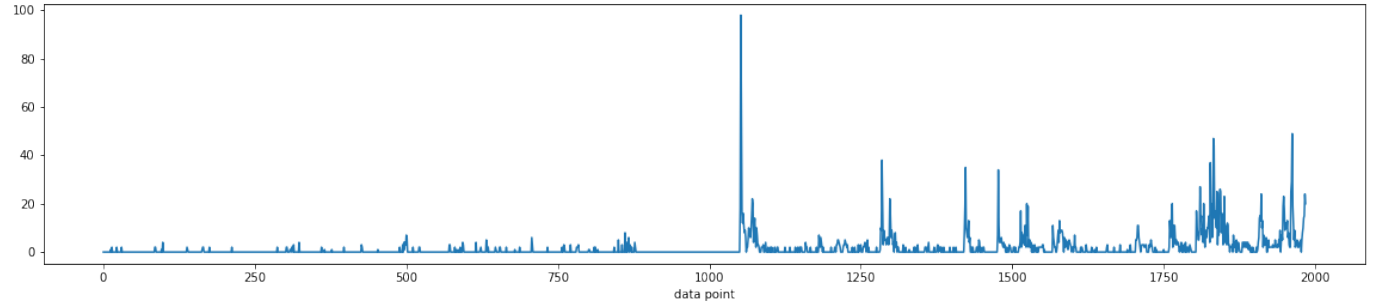

Abbildung 38: **Pferd 5** — Werte für *dphi*

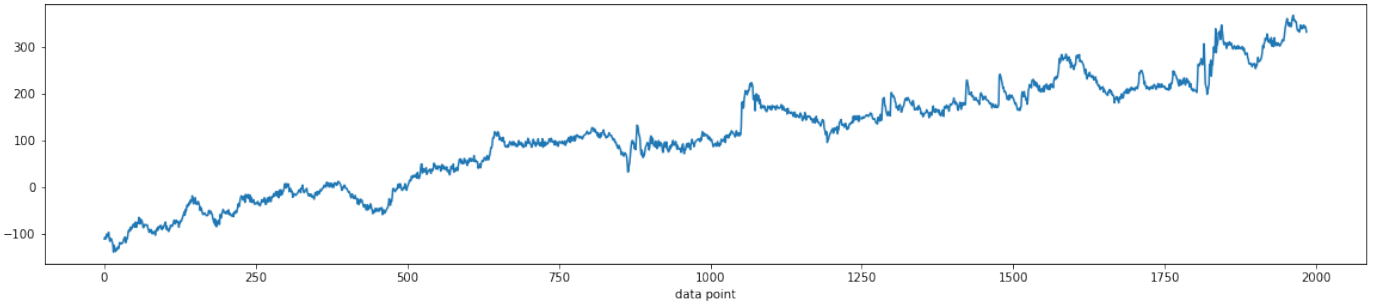

Abbildung 39: **Pferd 5** — Werte für *alt*

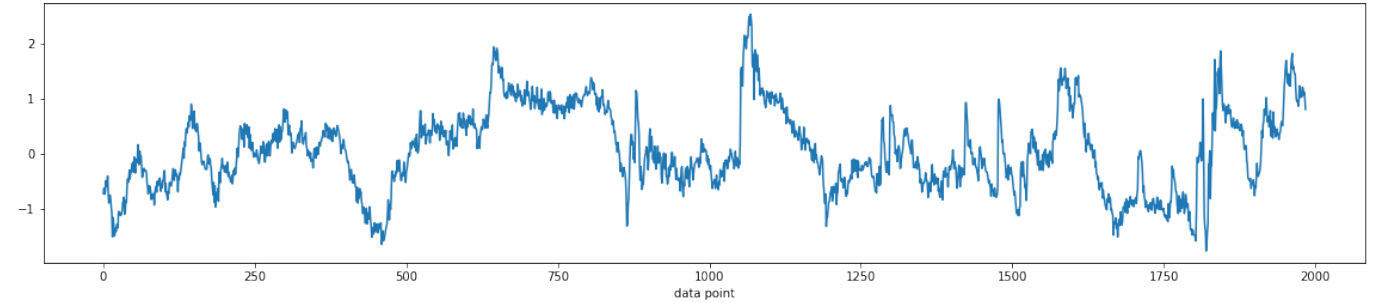

Abbildung 40: **Pferd 5** — angepasste Werte für *alt*

C. Darstellung der Videoanalysedaten anhand numerischer Werte

Abbildung 41: **Pferd 5** — Zugeordnete Werte für Kategorie Lage

Abbildung 42: **Pferd 5** — Zugeordnete Werte für Kategorie Kopfbewegung (horizontal)

Abbildung 43: **Pferd 5** — Zugeordnete Werte für Kategorie Kopfbewegung (vertikal)

Abbildung 44: **Pferd 5** — Zugeordnete Werte für Kategorie Drehung im Raum

D. Sensordaten eingefärbt für Kategorie Lage

Abbildung 45: **Pferd 1** — Werte für *yaw*, eingefärbt für Kategorie Lage

Abbildung 46: **Pferd 1** — Werte für *pitch*, eingefärbt für Kategorie Lage

Abbildung 47: **Pferd 1** — Werte für *roll*, eingefärbt für Kategorie Lage

Abbildung 48: **Pferd 1** — Werte für *dphi*, eingefärbt für Kategorie Lage

Abbildung 49: **Pferd 1** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage

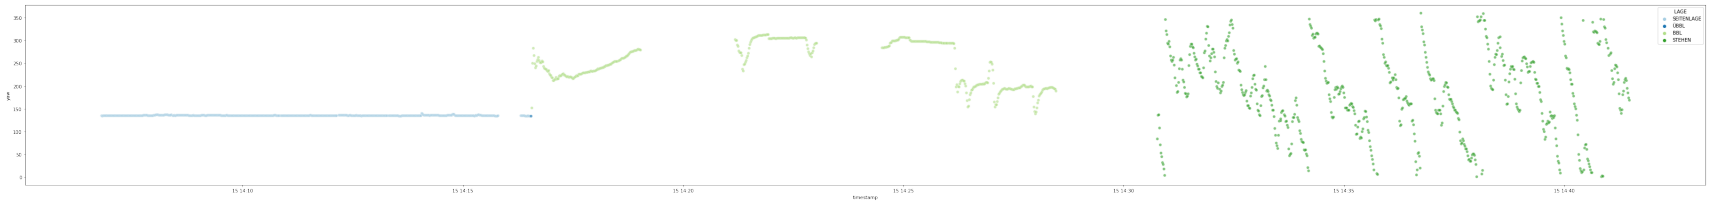

Abbildung 50: **Pferd 2** — Werte für *yaw*, eingefärbt für Kategorie Lage

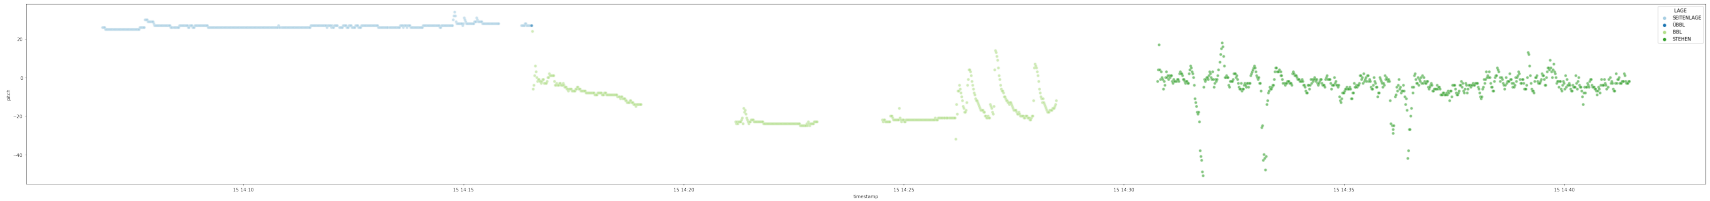

Abbildung 51: **Pferd 2** — Werte für *pitch*, eingefärbt für Kategorie Lage

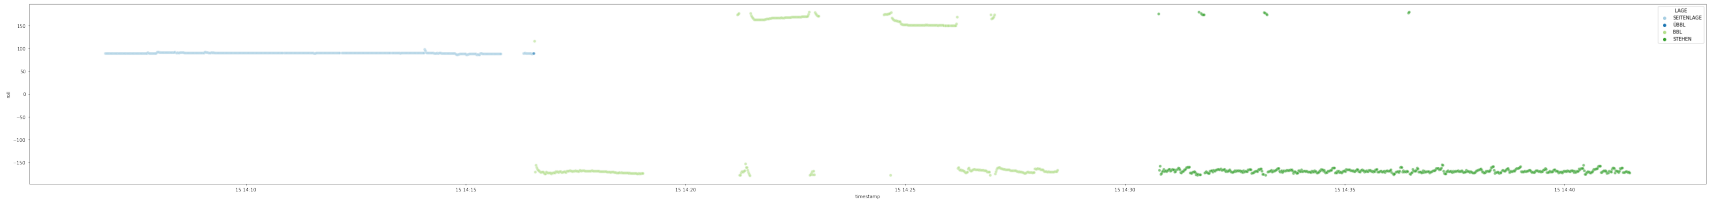

Abbildung 52: **Pferd 2** — Werte für *roll*, eingefärbt für Kategorie Lage

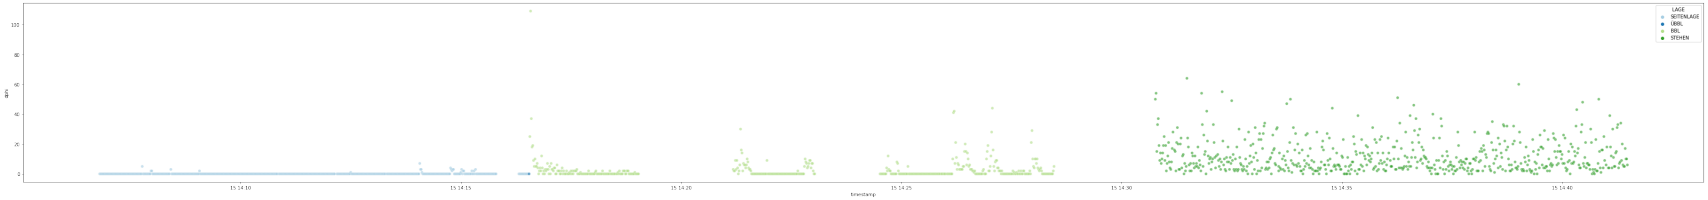

Abbildung 53: **Pferd 2** — Werte für *dphi*, eingefärbt für Kategorie Lage

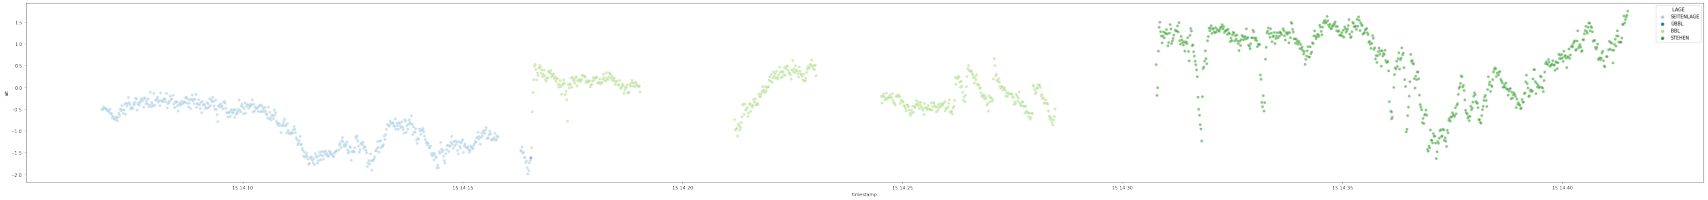

Abbildung 54: **Pferd 2** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage

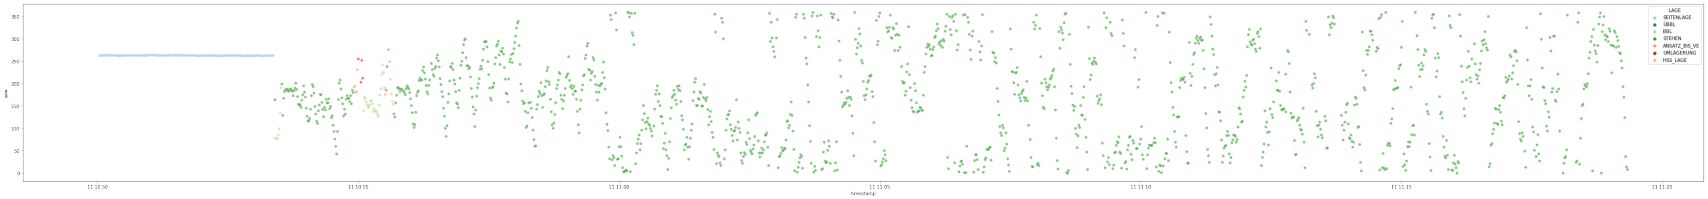

Abbildung 55: **Pferd 3** — Werte für *yaw*, eingefärbt für Kategorie Lage

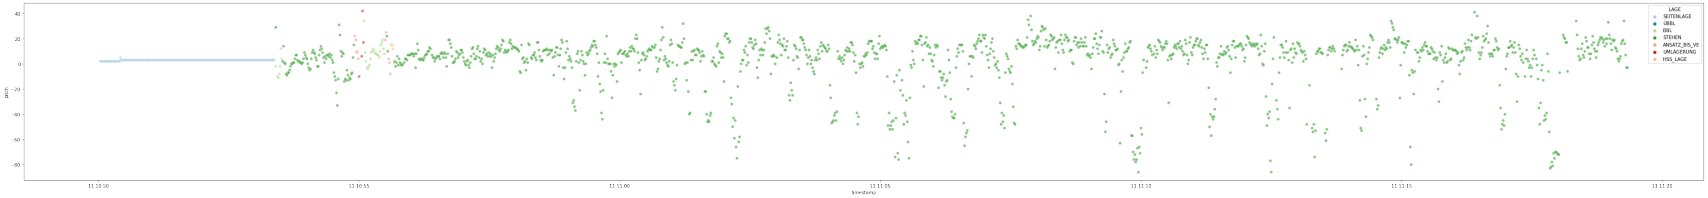

Abbildung 56: **Pferd 3** — Werte für *pitch*, eingefärbt für Kategorie Lage

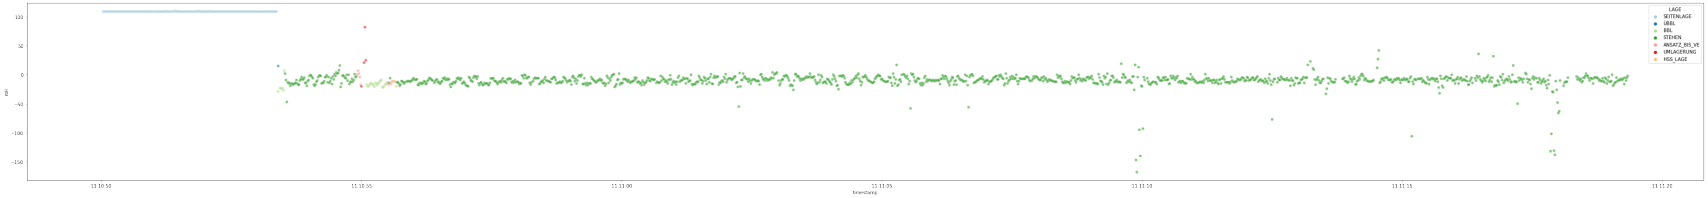

Abbildung 57: **Pferd 3** — Werte für *roll*, eingefärbt für Kategorie Lage

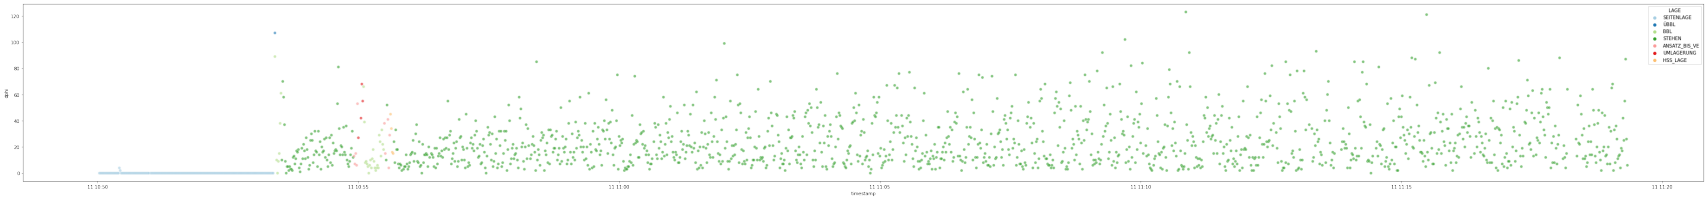

Abbildung 58: **Pferd 3** — Werte für *dphi*, eingefärbt für Kategorie Lage

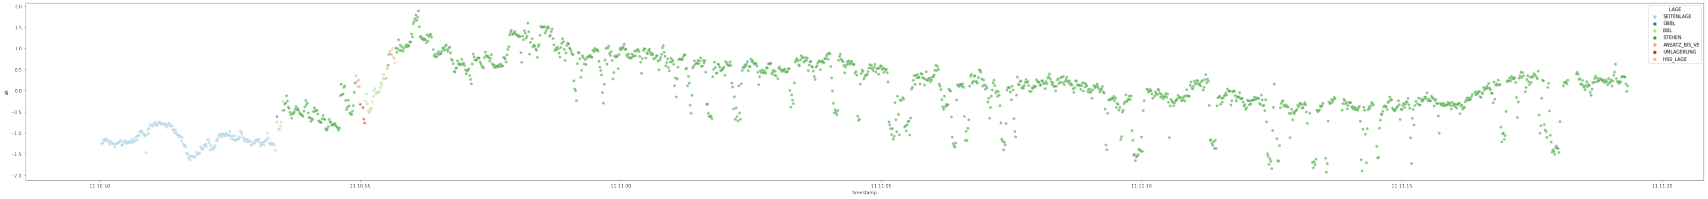

Abbildung 59: **Pferd 3** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage

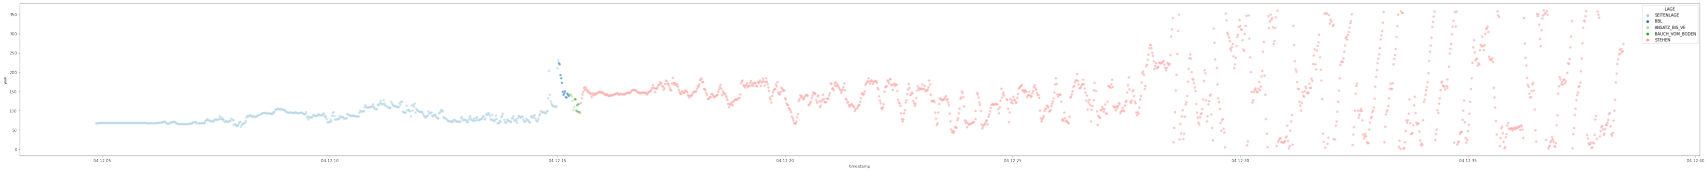

Abbildung 60: **Pferd 4** — Werte für *yaw*, eingefärbt für Kategorie Lage

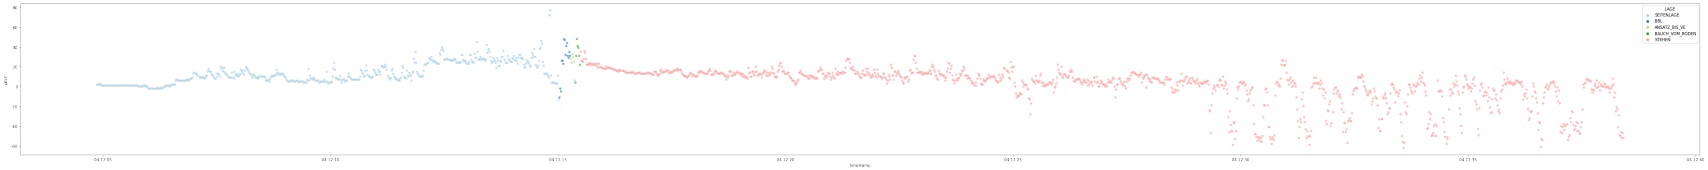

Abbildung 61: **Pferd 4** — Werte für *pitch*, eingefärbt für Kategorie Lage

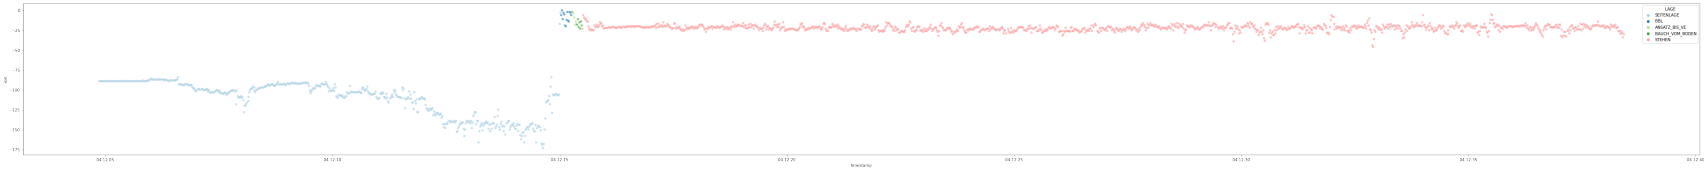

Abbildung 62: **Pferd 4** — Werte für *roll*, eingefärbt für Kategorie Lage

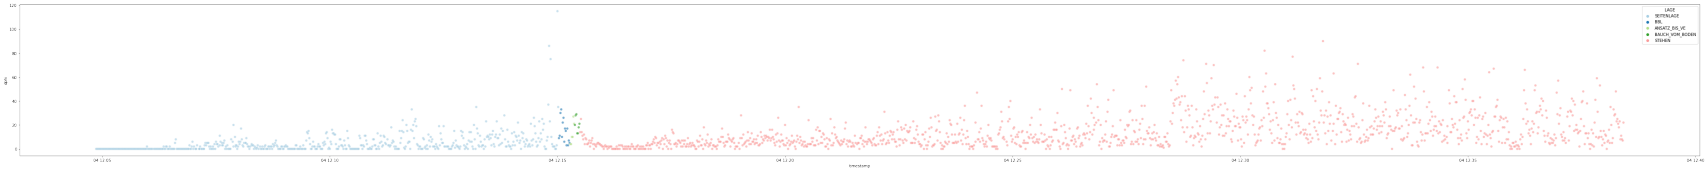

Abbildung 63: **Pferd 4** — Werte für *dphi*, eingefärbt für Kategorie Lage

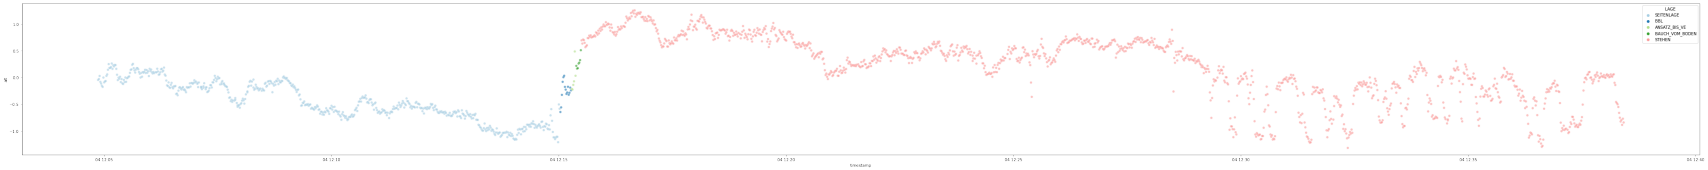

Abbildung 64: **Pferd 4** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage

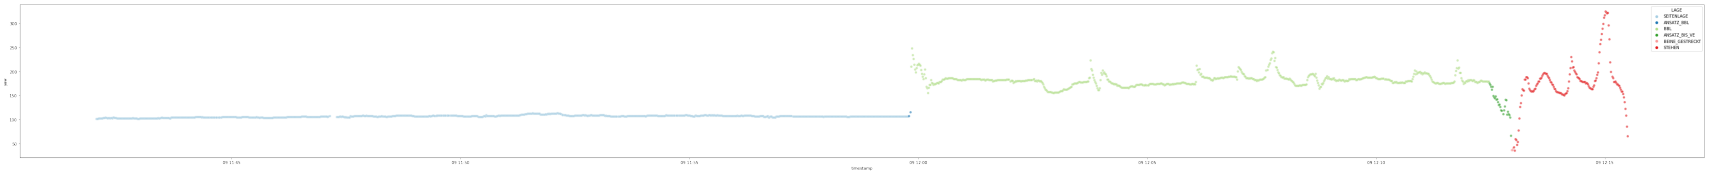

Abbildung 65: **Pferd 5** — Werte für *yaw*, eingefärbt für Kategorie Lage

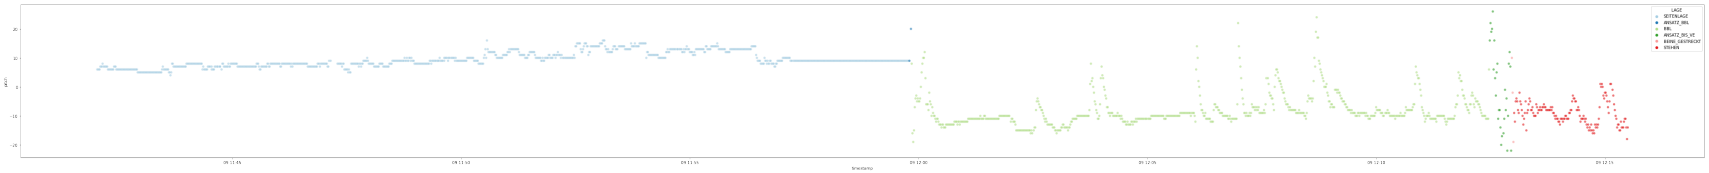

Abbildung 66: **Pferd 5** — Werte für *pitch*, eingefärbt für Kategorie Lage

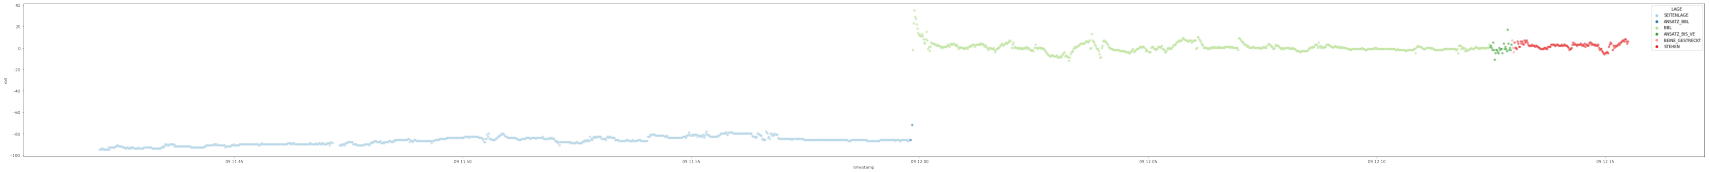

Abbildung 67: **Pferd 5** — Werte für *roll*, eingefärbt für Kategorie Lage

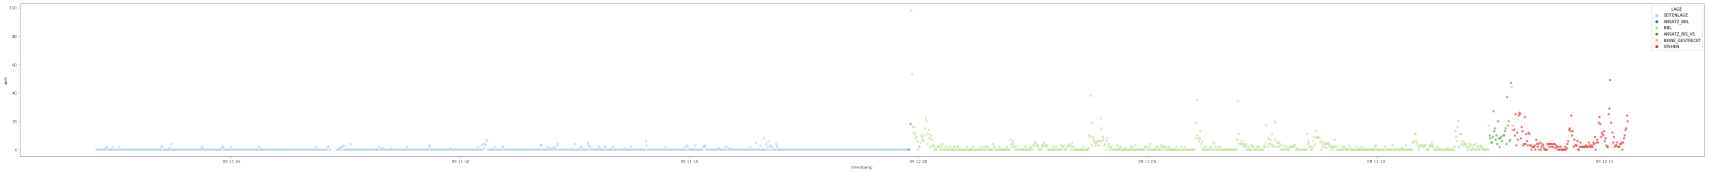

Abbildung 68: **Pferd 5** — Werte für *dphi*, eingefärbt für Kategorie Lage

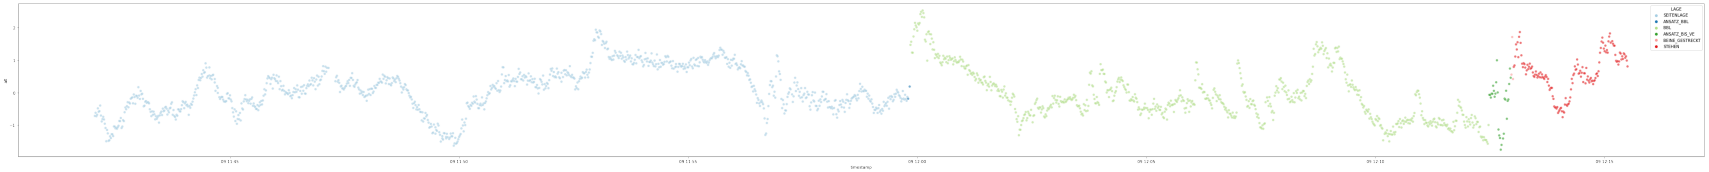

Abbildung 69: **Pferd 5** — angepasste Werte für *alt*, eingefärbt für Kategorie Lage

E. Sensordaten reduziert durch t-SNE

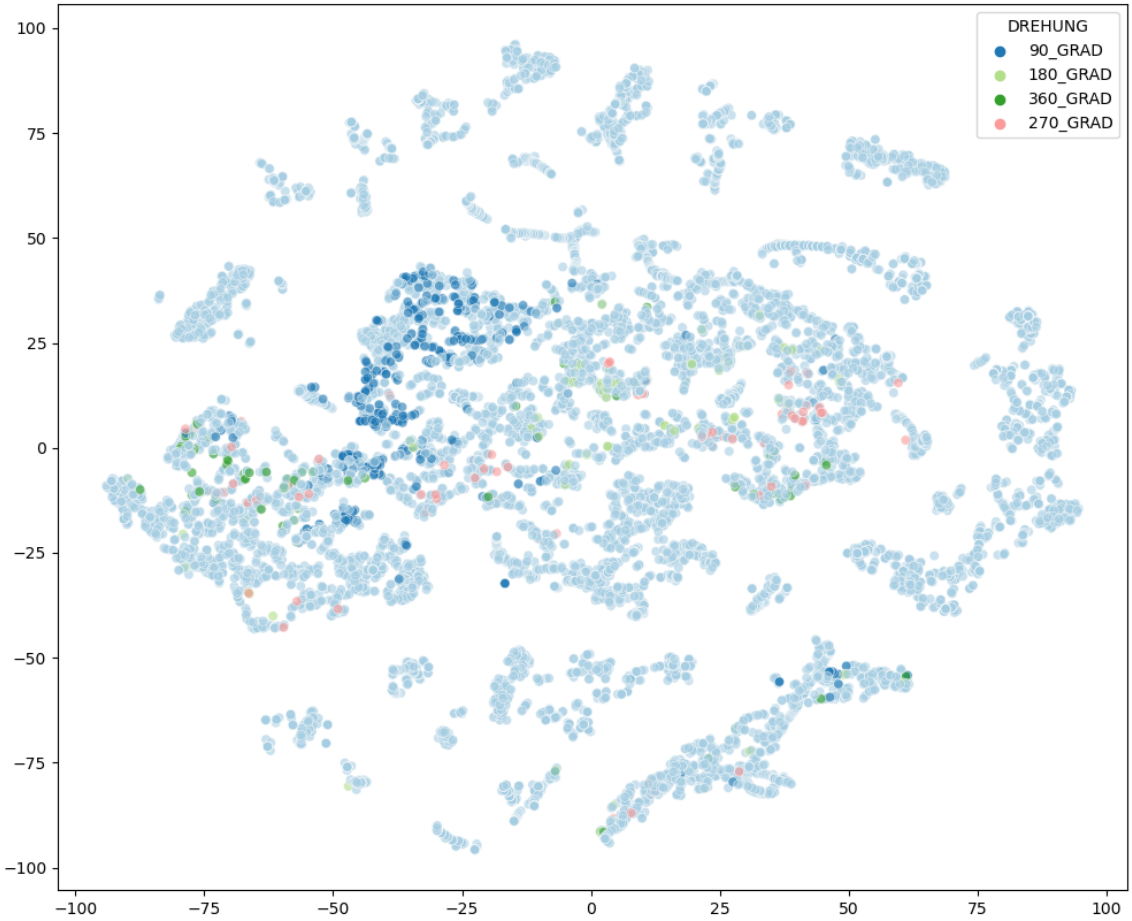

Abbildung 70: Sensordaten reduziert durch t-SNE, mit Klassifizierung für Drehung

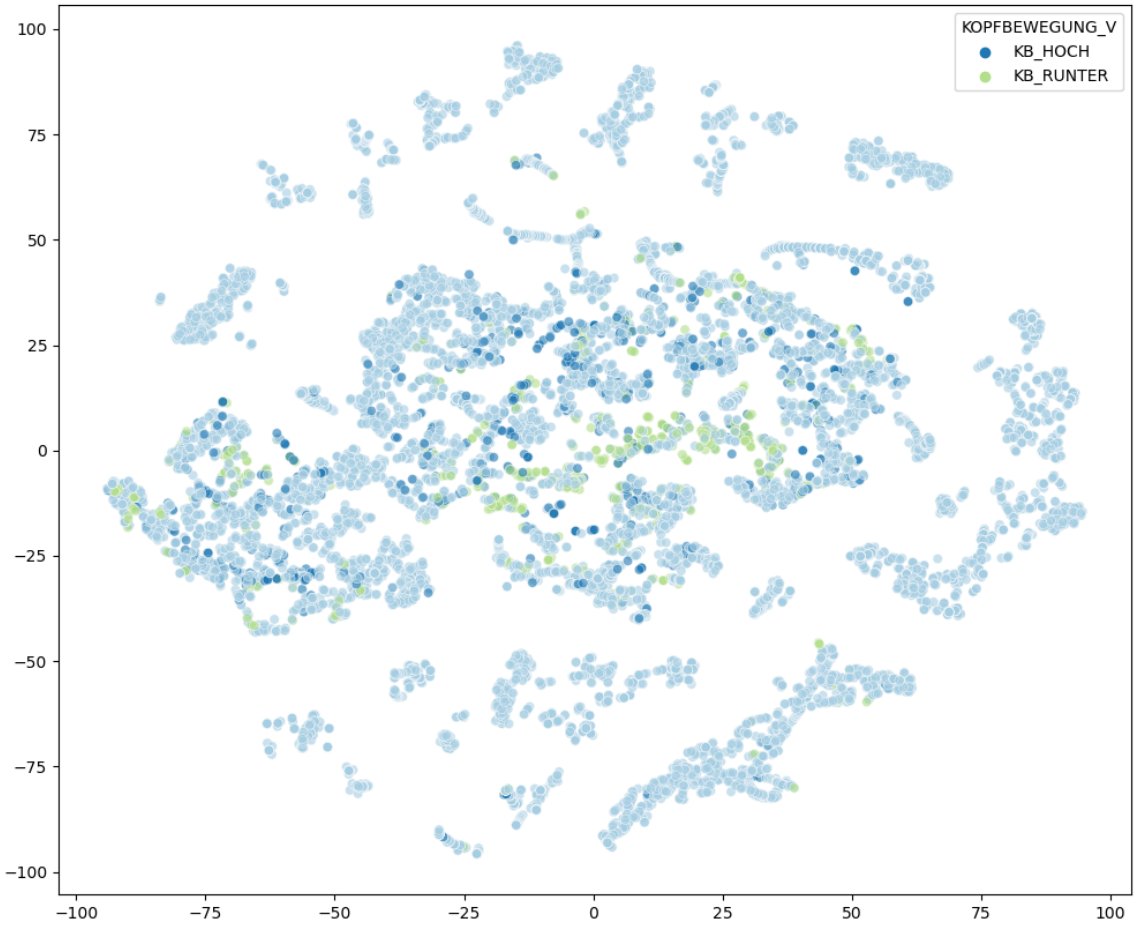

Abbildung 71: Sensordaten reduziert durch t-SNE, mit Klassifizierung für Kopfbewegung (vertikal)

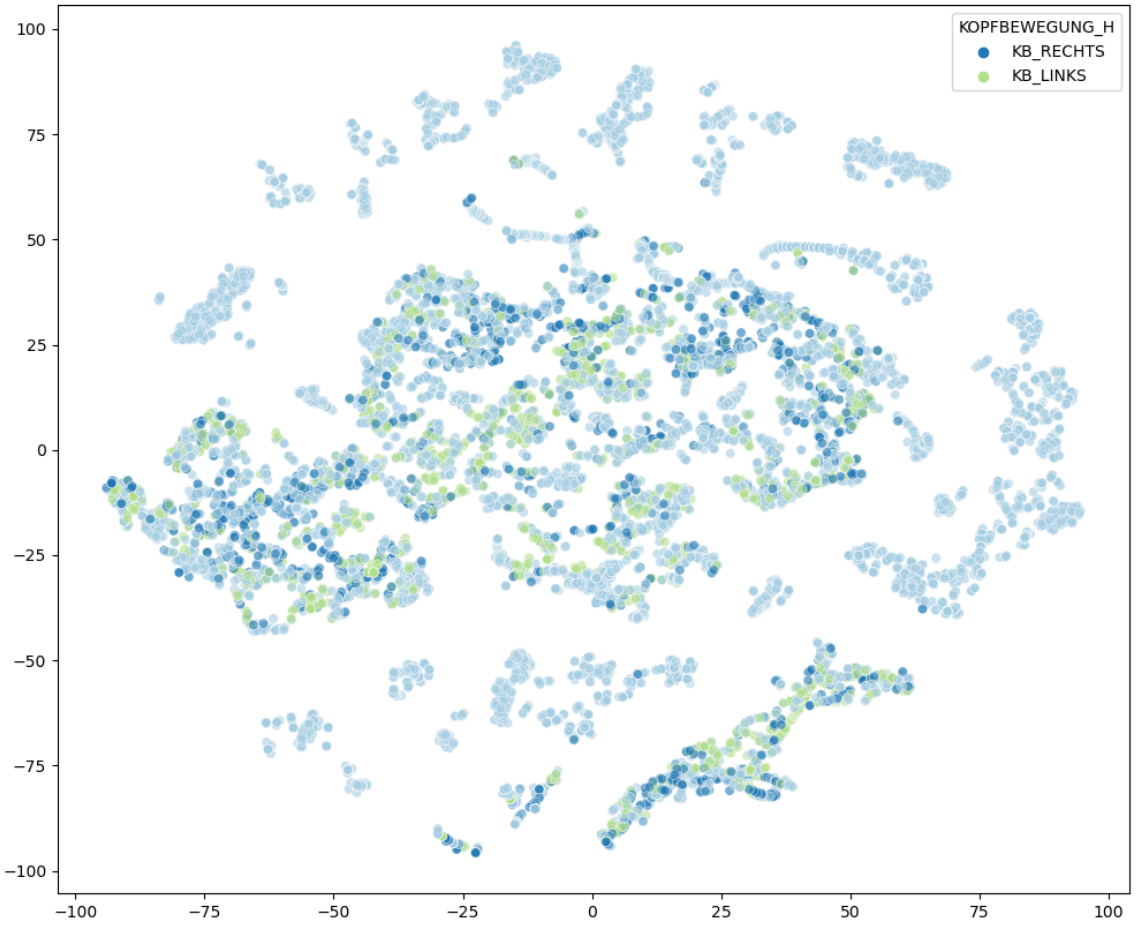

Abbildung 72: Sensordaten reduziert durch t-SNE, mit Klassifizierung für Kopfbewegung (horizontal)