UNIVERSIDADE ESTADUAL PAULISTA UNESP

CÂMPUS DE JABOTICABAL

MODELAGEM EM TEMPO REAL DAS EXIGÊNCIAS NUTRICIONAIS DE FRANGOS DE CORTE

Jaqueline de Paula Gobi

Zootecnista

2019

UNIVERSIDADE ESTADUAL PAULISTA UNESP

CÂMPUS DE JABOTICABAL

MODELAGEM EM TEMPO REAL DAS EXIGÊNCIAS NUTRICIONAIS DE FRANGOS DE CORTE

Jaqueline de Paula Gobi

Orientador: Prof. Dr. Luciano Hauschild

Coorientador: Dr. Candido Pomar

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Doutor em Zootecnia

2019

G575m

Gobi, Jaqueline de Paula

Modelagem em tempo real das exigências nutricionais de frangos de corte / Jaqueline de Paula Gobi. -Jaboticabal, 2019 71 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Luciano Hauschild

Coorientador: Candido Pomar

1. Nutrição. 2. Monogástricos. 3. Frangos de corte. 4. Modelagem matemática. 5. Alimentação. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MODELAGEM EM TEMPO REAL DAS EXIGÊNCIAS NUTRICIONAIS DE FRANGOS DE CORTE

AUTORA: JAQUELINE DE PAULA GOBI
ORIENTADOR: LUCIANO HAUSCHILD
COORIENTADOR: CÁNDIDO POMAR-GOMÁ

Aprovada como parte das exigências para obtenção do Título de Doutora em ZOOTECNIA, pela Comissão Examinadora:

Prof. Dr. LUCIANO HAUSCHILD
Departamento de Zootecnia / FCAV / UNESP - Jaboticabal

Profa. Dra. INES ANDRETTA (Videoconferência)
Departamento de Zootecnia-Universidade Federal do Rio Grande do Sul / Porto Alegre/RS

Prof. Dr. PAULO HENRIQUE REIS FURTADO CAMPOS (Videoconferência)
Departamento de Zootecnia-UFV / Viçosa/MG

Profa. Dra. SILVANA MARTINEZ BARALDI ARTONI
Departamento de Morfologia e Fisiologia Animal / FCAV / UNESP - Jaboticabal

EDNEY PEREIRA DA SILVA
Prof. Dr. EDNEY PEREIRA DA SILVA
Departamento de Zootecnia / FCAV / UNESP - Jaboticabal

Jaboticabal, 27 de fevereiro de 2019

DADOS CURRICULARES DO AUTOR

JAQUELINE DE PAULA GOBI - Filha de Dorival Paula Gobi e Maria Aparecida de Oliveira, nasceu no dia 19 abril 1990, na cidade de Ribeirão Preto, São Paulo. Em março de 2008 ingressou no curso de Zootecnia na Faculdade de Ciências Agrárias e Veterinárias da Universidade Estadual Paulista – Câmpus de Jaboticabal - São Paulo, graduando-se em dezembro de 2012. Durante o período de agosto de 2009 a julho de 2012 foi bolsista de Iniciação Científica pelo CNPq sob orientação da Profa. Dra. Nilva Kazue Sakomura e coorientação do Prof. Dr. Edney Pereira da Silva e integrante voluntária do Programa de Educação Tutorial (PET). Entre agosto e dezembro do mesmo ano realizou estágio curricular na *Korin* Agropecuária (Ipeúna – SP) onde desenvolveu atividades na área de produção orgânica de frangos de corte. Em março de 2013 iniciou o curso de Mestrado em Zootecnia pela mesma instituição sob orientação do Prof. Dr. Luciano Hauschild e coorientação da Profa. Dra. Ines Andretta, tendo defendido sua dissertação em 18 de fevereiro de 2015. Em março de 2015 iniciou o curso de doutorado, sob orientação do Prof. Dr. Luciano Hauschild e coorientação do Dr. Candido Pomar, submetendo- se ao processo de defesa da tese em 27 de fevereiro de 2019.

AGRADECIMENTOS

Ao professor Luciano Hauschild pela orientação ao longo de meu mestrado e doutorado. Sou extremamente feliz por ter me escolhido como sua orientada e extremamente grata pelos ensinamentos técnicos e pessoais que obtive e pela confiança que depositou em mim nesse período.

Ao meu coorientador Candido Pomar, pelo grande auxílio no desenvolvimento da tese e a receptividade ao receber-me no Centro de Pesquisa *Agri-Food Canada*.

À minha equipe de trabalho: Aline Remus, Alini Veira, Camila Bueno, Candido Pomar, Cintia Fracarolli, Dani Perondi, Ines Andretta Luan Sousa, Luciano Hauschild, Marcos Kipper, Raphael Caetano, Renan Isola e Welex Candido. Uma página seria muito pouco para expressar a gratidão e o carinho que tenho por cada um de vocês. De qualquer forma, fica aqui registrado meus mais sinceros agradecimentos.

Aos professores membros da banca de defesa da tese Dr. Edney Pereira da Silva, Dra. Ines Andreta, Dr. Luciano Hauchild, Dr. Paulo Campos e Dra. Silvana Artoni pelo aceite ao convite e pela relevante contribuição no material técnico do presente trabalho.

Agradeço imensamente a oportunidade de ter sido aluna da Faculdade de Ciências Agrárias e Veterinárias UNESP Jaboticabal que, muito mais que responsável pela minha formação técnica, foi minha casa ao longo de dez anos e geradora das minhas maiores amizades. As “meninas de casa”, “Vizis”, “pessoal do PET”, “galera do aviário”, “zoo08”, “*team* Hauschild”... cada grupo ao qual pertenci/pertenço me tornaram a pessoa que sou hoje. Obrigada a todos que fizeram e fazem parte da minha história.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e da FAPESP (projeto nº 2012/03781-0).

SUMÁRIO

MODELAGEM EM TEMPO REAL DAS EXIGÊNCIAS NUTRICIONAIS DE FRANGOS DE CORTE

RESUMO – A busca por estratégias que visem uma alimentação e nutrição mais precisas são fundamentais para melhor atendimento dos diferentes objetivos de produção. A produção animal de precisão é um conceito que permite considerar a variabilidade entre animais e diferentes condições de produção. Nesse contexto, a nutrição de precisão envolve o uso de técnicas de alimentação que permitem fornecer uma dieta especifica para os animais considerando a evolução do consumo e crescimento e as respectivas variabilidades observadas em tempo real. Modelos matemáticos podem atuar em conjunto com um sistema de manejo integrado para promover uma nutrição de precisão. A maioria dos modelos utilizados atualmente em nutrição de frangos de corte é de natureza retrospectiva, os quais são contestados quanto à sua eficácia devido à necessidade de uma adequada calibração em relação a uma população de referência. O estabelecimento de programas nutricionais para uma população específica, levando em consideração a resposta média e variabilidade do consumo e crescimento coletados em tempo real permite avançar para o conceito de nutrição de precisão para frangos de corte. Contudo, a variabilidade para o consumo em uma condição comercial não pode ser determinada, somente o consumo e peso vivo médios. Na produção animal, modelos de crescimento têm sido utilizados para estimar as exigências de uma população com base em um único indivíduo (fatorial) ou da resposta da população (dose resposta). Essas respostas de indivíduo e população são estabelecidas a partir de informações coletadas previamente de populações com pouca variabilidade. Nesse contexto, esses modelos estimam exigências nutricionais de um grupo de animais com base na suposição de que o potencial desses animais é similar a população referência. Assim, os objetivos do presente trabalho foram: (1) Desenvolver um método para estimar variabilidade do consumo de ração de uma população de frangos de corte a partir de variáveis passíveis de serem mensuradas em tempo real e (2) Desenvolver um modelo matemático que permita estimar as exigências em aminoácidos em tempo real para uma população de frangos de corte. Para estimativa da variabilidade do consumo, foram utilizadas bases de dados de estudos previamente publicados para estudo da interdependência entre peso vivo e consumo de ração acumulado, dados esses que permitiram o ajuste de uma equação que estima, a partir da variabilidade do peso vivo, a variabilidade do consumo de ração e pode ser aplicada em um modelo matemático que atue em conjunto com um sistema de manejo integrado para estimar exigências nutricionais com base na variabilidade do consumo e do ganho de peso de uma população de frangos de corte. Nesse sentido, foi desenvolvido um modelo matemático com componentes empíricos e mecanicistas para estimar as exigências diárias de lisina de uma população de frangos de corte. O modelo foi avaliado com dados de um estudo que investigou o efeito da alimentação de frangos de corte em um sistema multifases. A capacidade do modelo em estimar a exigência de aminoácidos para populações com diferentes heterogeneidades foi avaliada simulando condições com menor e maior variabilidade. Por fim, o modelo proposto foi avaliado comparando suas estimativas com as estimativas geradas pelo modelo de crescimento Avinesp. As trajetórias de consumo de ração e ganho de peso diários e desvio padrão de consumo de ração acumulado foram preditas com erro percentual médio absoluto menor do que o predito para o modelo Avinesp. A concentração média de lisina digestível ileal padronizada na dieta (SIDLys) estimada pelo modelo proposto foi semelhante aos valores obtidos pelo Avinesp, no entanto, apenas o modelo proposto permitiu estimar a exigência do SIDLys para o 80 percentil do lote. Baseado em modelagem recursiva, estimativas da variabilidade da eficiência alimentar e usando a equação fatorial, o modelo proposto no presente estudo estima dinamicamente os requisitos de aminoácidos para frangos de corte levando em conta a heterogeneidade da população.

Palavras-chave: aves, aminoácidos, modelagem em tempo real, nutrição de precisão.

REAL-TIME MODELING OF THE NUTRITIONAL REQUIREMENTS OF BROILERS

ABSTRACT – The search for strategies aimed at a more precise feeding and nutrition are fundamental to better serve the different production objectives. Precision animal production is a concept that allows to consider the variability between animals and different conditions of production. In this context, precision nutrition involves the use of feeding techniques that allow to provide a specific diet for the animals considering the evolution of feed intake and growth and the respective variabilities observed in real time. Mathematical models can work in combination with an integrated management system to promote precision nutrition. Most of the models currently used in broiler nutrition are retrospective, which are challenged as to their efficacy due to the need for an adequate calibration in relation to a reference population. The establishment of nutritional programs for a specific population, taking into account the average response and variability of feed intake and growth collected in real time, allows to advance to the concept of precision nutrition for broiler chickens. However, the variability for consumption in a commercial condition cannot be determined, only feed intake and average live weight. In animal production, growth models have been used to estimate the requirements of a population based on a single individual (factorial) or population response (dose response). These individual and population responses are established from information previously collected from populations with low variability. In this context, these models estimate the nutritional requirements of a group of animals based on the assumption that the potential of these animals is similar to the reference population. Thus, the objectives of the present study were: (1) To develop a method to estimate the variability of feed intake of a broiler population from variables that can be measured in real time; and (2) To develop a mathematical model that allows to estimate the real-time amino acid requirements for a broiler population. In order to estimate the variability of feed intake, previously published databases were used to study the interdependence between live weight and accumulated feed intake, which allowed the adjustment of an equation that estimates, from the body weight variability, the feed intake variability can be applied in a mathematical model that works together with an integrated management system to estimate nutritional requirements based on the variability of the feed intake and the weight gain of a population of broilers. In this sense, a mathematical model with empirical and mechanistic components was developed to estimate the daily requirements of amino acids of a population of broilers. The model was evaluated with data from a study that investigated the effect of feeding broiler chickens with a multiphase system. The ability of the model to estimate the amino acid requirement for populations with different heterogeneities was evaluated simulating conditions with lower and higher variability. Finally, the proposed model was evaluated comparing its estimates with the estimates generated by the Avinesp growth model. Daily feed intake and weight gain trajectories and standard deviation of cumulative feed intake were predicted with mean absolute percentage error lower than that predicted for the Avinesp model The mean dietary standardized ileal digestible lysine concentration (SIDLys) estimated by the model However, only the proposed model allowed to estimate the requirement of SIDLys for the 80th percentile of the population. Based on recursive modeling, estimates of food efficiency variability and using the factorial equation, the model proposed dynamically estimates the amino acid requirements for broilers taking into account the heterogeneity of the population.

Keywords: amino acids, birds, precision nutrition, real time mathematical models,

LISTA DE ABREVIATURAS

1. AA - Amino acid
2. BW - Body weight
3. Corr(CRA,PV) - Correlação entre consumo de ração acumulado e peso vivo
4. Cov(CRA,PV) - Covariância entre consumo de ração acumulado e peso vivo
5. CR - Consumo de ração
6. CRA - Consumo de ração acumulado
7. CuFI - Cumulative feed intake
8. CVBW - Coefficient of variation of body weight
9. CVRef - Coeficiente de variação de referência / Reference variability
10. DBC - Delineamento em blocos casualizados
11. DFI - Daily feed intake
12. DG - Daily gain
13. DP - Desvio padrão
14. EC - Empirical component
15. Eff - Average feed efficiency
16. EP - Erro padrão da média
17. Fc - Fator de correção / Correction factor
18. HighVar - Higher variability
19. LowVar - Lower variability
20. MAPE - Mean absolute percentage error
21. MC - Mechanistic component
22. RelVarEff - Variability of feed efficiency
23. SIDLys - Standardized ileal digestible lysine
24. SD - Standard deviation
25. SD BW - Standard deviation of body weight
26. ADG - Average daily gain
27. ADFI - Average daily feed intake
28. SDCuFI - Standard deviation of cumulative feed intake
29. covBWCuFI - Covariance between body weight and cumulative feed intake
30. corrBWCuFI - Correlation between body weight and cumulative feed intake
31. SDEff - Standard deviation of feed efficiency

32. PD - Protein deposition
33. SIDLysM - Lysine maintenance requirement
34. SIDLysG - Lysine gain requirement
35. Lysconc - Concentration of lysine in protein deposition
36. Efflys - utilization efficiency of standardized ileal digestible lysine for protein deposition
37. SIDlys% - standardized ileal digestible lysine concentration
38. SIM - Sistema integrado de manejo
39. LRP - Linear response plateau
40. PV – Peso vivo
41. QLP – Quadratic linear plateau

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

1. INTRODUÇÃO E JUSTIFICATIVA

A alimentação representa mais de 60% dos custos de produção das aves. A redução do custo da alimentação está relacionada a disponibilidade da matéria-prima e das estratégias nutricionais e alimentares adotadas. Os programas nutricionais atuais visam minimizar custo através do ajuste da composição nutricional dos ingredientes da dieta com as exigências nutricionais dos animais. Além disso, outro aspecto relevante é a sustentabilidade da produção animal que, além da redução de custos e máximo desempenho, considera também a qualidade do produto final, o bem-estar animal e o impacto ambiental. Nesse sentido, a busca por estratégias que visem uma alimentação e nutrição mais precisas são fundamentais para avançar em sentido ao atendimento destes diferentes objetivos de produção.

As exigências nutricionais das aves são, atualmente, estimadas por dois métodos: dose resposta ou fatorial (Hauschild et al., 2010). Adicionalmente, os modelos matemáticos de crescimento, os quais integram ambos métodos também têm sido utilizados para estimar exigências para lotes de frangos de corte. Estes modelos de crescimento devem ser devidamente calibrados em relação a uma população referência. Devido a esse aspecto, os modelos de crescimento atuais têm sido contestados pela dificuldade de identificar a população referência adequada no processo de calibração. Isso pois os lotes de aves podem seguir diferentes padrões de consumo e crescimento daqueles observados na população referência. Adicionalmente, esses modelos apresentam limitações na estimativa do crescimento e das exigências nutricionais em populações heterogênias.

A produção animal de precisão é um conceito que permite considerar a variabilidade entre animais e em diferentes condições de produção. Nesse contexto, a nutrição de precisão envolve o uso de técnicas de alimentação que permitem fornecer uma dieta especifica para os animais considerando a evolução do consumo e crescimento e as respectivas variabilidades observadas em tempo real (Pomar et al., 2009). Avanços importantes foram obtidos com suínos, contudo com aves os estudos ainda são incipientes em nutrição de precisão. Ainda assim, alguns adventos tecnológicos já permitem monitorar as respostas (consumo e peso) como também formular e fornecer uma dieta diariamente para frangos de corte. A integração nesses sistemas permite estimar exigências nutricionais, considerando a dinâmica do consumo e crescimento e suas respectivas variabilidades em tempo real. Isto representa um passo importante em direção a uma nutrição de precisão para frangos de corte. Essa proposta representa uma mudança importante de paradigma na alimentação de frangos, pois o nível ideal de nutrientes não será considerado estático (população referência) e sim um processo dinâmico estabelecido com base na resposta obtida em tempo real de lotes comerciais de frangos.

2. REVISÃO DE LITERATURA

2.1. Estado atual dos programas nutricionais

As pesquisas em alimentação e nutrição estão focadas em estudar principalmente três aspectos: a composição nutricional e digestibilidade dos ingredientes, as exigências nutricionais dos animais e a resposta animal em termos de retenção e excreção de nutrientes (Whittemore, 2001). Com base nesses aspectos, os programas nutricionais têm sido estabelecidos pelo balanço entre a oferta de nutrientes dos ingredientes e as exigências nutricionais dos animais (Patience et al., 1995). Adicionalmente, as dietas têm sido fornecidas majoritariamente com base em programas de alimentação por fases. Essa técnica envolve o fornecimento de um número sucessivo de dietas (3 a 5 fases) aos animais com o objetivo de atender as exigências nutricionais dos animais em função da idade ou peso vivo dos animais. Nesse programa, geralmente é considerado a exigência para o período médio de cada fase. Dessa forma os animais recebem níveis nutricionais acima ou abaixo das exigências nutricionais em determinado período do crescimento (Buteri et al., 2009). Isso reflete, consequentemente, em impacto ambiental, devido a excreção de elementos poluidores como nitrogênio e fósforo (Nahm, 2007).

2.1.1. Métodos e modelos para estimar exigências nutricionais

A exigências de um nutriente pode ser definida como a quantidade de nutrientes necessária para atingir objetivos específicos de produção como maximizar o ganho de peso, ganho de tecido magro e/ou melhorar a conversão alimentar (Fuller, 2004). Entretanto, a intensificação da indústria tem forçado os nutricionistas a desenvolverem estratégias onde outros objetivos de produção além da máxima resposta devem ser também otimizados (ex: econômicos, ambientais, etc.). Além disso, existe uma pressão para realização de pesquisas direcionadas para uma nutrição mais precisa com o objetivo de estimar o potencial nutritivo dos ingredientes e ajustar as exigências nutricionais com melhor acurácia em relação ao estado fisiológico do animal em condições de produção.

Nos programas nutricionais atuais, as exigências têm sido estimadas pelos métodos dose-resposta e fatorial. No método dose-resposta, as exigências nutricionais são estabelecidas com base na resposta da população onde os níveis ideais são considerados para maximizar ou minimizar um ou vários parâmetros de desempenho. No método fatorial, as exigências diárias são estimadas com base em um único indivíduo representativo da população (exemplo: indivíduo médio) e calculadas pela soma das exigências para mantença e produção (Fuller & Chamberlain, 1982). Devido à complexidade e aos inúmeros fatores que modulam as respostas dos animais, modelos matemáticos que integram o metódo dose resposta e fatorial têm sido propostos para simular o crescimento e estimar exigências nutricionais para diferentes condições de produção (Green; Whittemore, 2003; Van Milgen et al., 2008).

Existem diferentes tipos de modelos: empíricos ou mecanicistas, determinísticos ou estocásticos, estáticos ou dinâmicos, retrospectivos (calibrados *a priori*) ou em tempo real, dentre outros. A maioria dos modelos utilizados na nutrição de monogástricos são mecanicistas, determinísticos e dinâmicos (Black et al., 1986, EFG, 2006, Emmans, 1981, Fisher et al., 1973, Inraporc, 2006). Com relação à calibração, os modelos podem ser desenvolvidos para operar em modo retrospectivo ou em tempo real. A maioria dos modelos utilizados atualmente em nutrição de frangos de corte é de natureza retrospectiva, tais como o Avinesp (Hauschild et al., 2014) e o EFG (EFG, 2006), os quais são calibrados com base em um banco de dados obtido *a priori*. Estes modelos foram desenvolvidos para estimar o efeito de diferentes fatores (alimento, ambiente, etc) nas respostas dos animais. A eficácia destes modelos está atrelada à sua adequada calibração em relação a uma população de referência. Entretanto, estes modelos são contestados devido à dificuldade de identificar uma população referência adequada para a calibração. Isso está relacioando ao fato que animais de populações atuais podem seguir diferentes padrões de crescimento quando comparados aos observados na população referência (Pomar et al., 2009). Adicionalmente, as exigências nutricionais variam em forma e magnitude entre individuos de uma população (Hauschild et al., 2010). Vários estudos têm demonstrado que a utilização do indivíduo médio (modelo determinista) para estimativa da exigência de uma população implica que grande parte dos animais não serão atendidos e, consequentemente, o potencial não será maximizado (Pomar et al., 2003; Brossard et al., 2009; Hauschild et al., 2010). Novas abordagens que permitem simular uma população (modelos estocásticos) pela variação e relação entre parâmetros do modelo têm sido propostas (van Milgen et al., 2008; Brossard et al., 2009). Contudo, essas abordagens ainda operam com base em uma população referência sem levar em consideração a atual variação observada em tempo real nos animais. Assim, embora sejam ferramentas úteis para auxiliar os nutricionistas nas tomadas de decisões, a maioria dos modelos de crescimento atuais têm dificuldade em considerar as diferenças entre as populações, a variabilidade e as mudanças que poderão aparecer durante o curso do crescimento ao estimar um nível ideal de nutriente na dieta.

2.2. Nova abordagem para estimar exigências nutricionais com base no conceito de Nutrição de Precisão

A nutrição de precisão é um conceito que considera aspectos de variabilidade inter e intra-unidades de produção (Wathes et al., 2008). Esta variabilidade resulta das diferenças entre os animais no que se refere à genética, idade e peso. Além dessa variação intrínseca ao animal, existem também variações extrínsecas, as quais são determinadas por fatores externos (temperatura, desafios sanitários, alimentação, etc.) que influenciam o desempenho dos animais e as exigências nutricionais.

A nutrição de precisão, por considerar a variabilidade das respostas biológicas dos animais, tem se mostrado uma estratégia efetiva para melhorar a eficiência nutricional dos animais e assim reduzir impacto ambiental e custo (Andretta et al., 2017). A importância de se considerar a variabilidade nos programas nutricionais tem sido demonstrada em vários estudos com suínos (Pomar et al., 2003; Wathes et al., 2008; Brossard et al., 2009; Santos et al., 2018). Contudo, para frangos de corte poucos estudos com nutrição de precisão foram realizados. Isso está relacionado ao fato da dificuldade de monitoramento da resposta de cada individuo dentro de uma população comercial de frangos de corte. Contudo, alguns adventos tecnológicos permitem monitorar a resposta média e a variabilidade populacional em granjas comerciais. O estabelecimento de programas nutricionais para uma população específica, levando em consideração a resposta média e a variabilidade obtidas em tempo real podem permitir um avanço importante em direção a uma nutrição de precisão para frangos de corte.

A aplicação do conceito de nutrição de precisão, entretanto, é dependente do uso de sistemas integrados de manejo (SIM) similares ao proposto por Parsons et al. (2007), o qual permite monitorar os processos biológicos e físicos (Figura 1) na produção animal (Wathes et al., 2008).

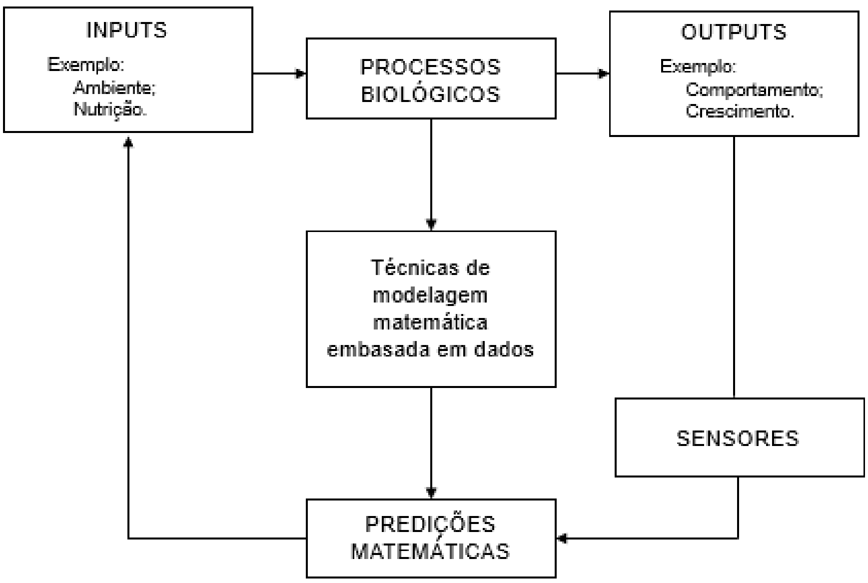

Figura 1. Visão geral esquemática dos principais componentes de um SIM. Adaptado de Wathes et al., 2008

Atualmente, grande parte do processo de produção animal pode ser submetido à automação, devido a existência de equipamentos para monitorar, alimentar e controlar o ambiente dos animais. O SIM não representa apenas uma forma de combinar esses vários subsistemas, mas também um mecanismo de delegar controles automáticos sobre eles. Sistemas automáticos de pesagem para frangos de corte, por exemplo, têm sido desenvolvido para estimar o PV médio e variabilidade de um lote em tempo real (Turner et al., 1984). A mensuração do esvaziamento dos silos de ração, por meio de balanças acopladas em suas bases, permite a estimativa do consumo médio de ração de um lote. Contudo, não permite determinar a variabilidade do consumo para o lote. Algumas tecnologias alternativas têm sido propostas para estimar a variabilidade do consumo de aves de forma indireta, tais como por intermédio da vocalização (Zimmerman et al., 2000) e ruídos sonoros (Aydin et al., 2014). Entretanto, embora apresentem resultados promissores do ponto de vista científico, tais sistemas são de difícil aplicação dentro de um contexto prático de produção. Dessa forma, embora equipamentos estejam disponíveis para mensuração do peso médio e variabilidade, no caso do consumo não existe um sistema que possa ser utilizado em condições comerciais para mensurar a variabilidade. Dessa forma, métodos que propiciem a estimativa da variabilidade do consumo devem ser propostos para avançar no estabelecimento de programas nutricionais com base na média e variabilidade do consumo e peso vivo.

Os potenciais benefícios dos sistemas de alimentação de precisão são vários (Pomar et al., 2009). No caso da alimentação, esses sistemas são uma abordagem essencial para melhorar a eficiência de utilização do N, P e outros nutrientes diminuindo assim a excreção desses elementos no meio ambiente. Por meio desses sistemas, torna-se possível o fornecimento de uma dieta mais ajustada às exigências nutricionais dos animais, permitindo uma melhoria de aspectos relacionados à sanidade, bem-estar e ambiente dos animais. Entretanto, sua eficiência no que se refere à nutrição está relacionada, entre outros fatores, à determinação das exigências nutricionais dos animais e a formulação de dietas que ajuste de forma concomitante o aporte de nutrientes às exigências dos animais em tempo real. Esse ajuste requer o conhecimento das exigências nutricionais de uma população em função do atual estado e da evolução do consumo e crescimento e as respectivas variabilidades no tempo (Pomar et al., 2009). Em suma, no caso de frangos de corte, a efetividade de um sistema de nutrição de precisão requer um modelo matemático que permita estimar com base nas respostas mensuradas (média e variabilidade) as exigências nutricionais em tempo real dos lotes (Figura 2).

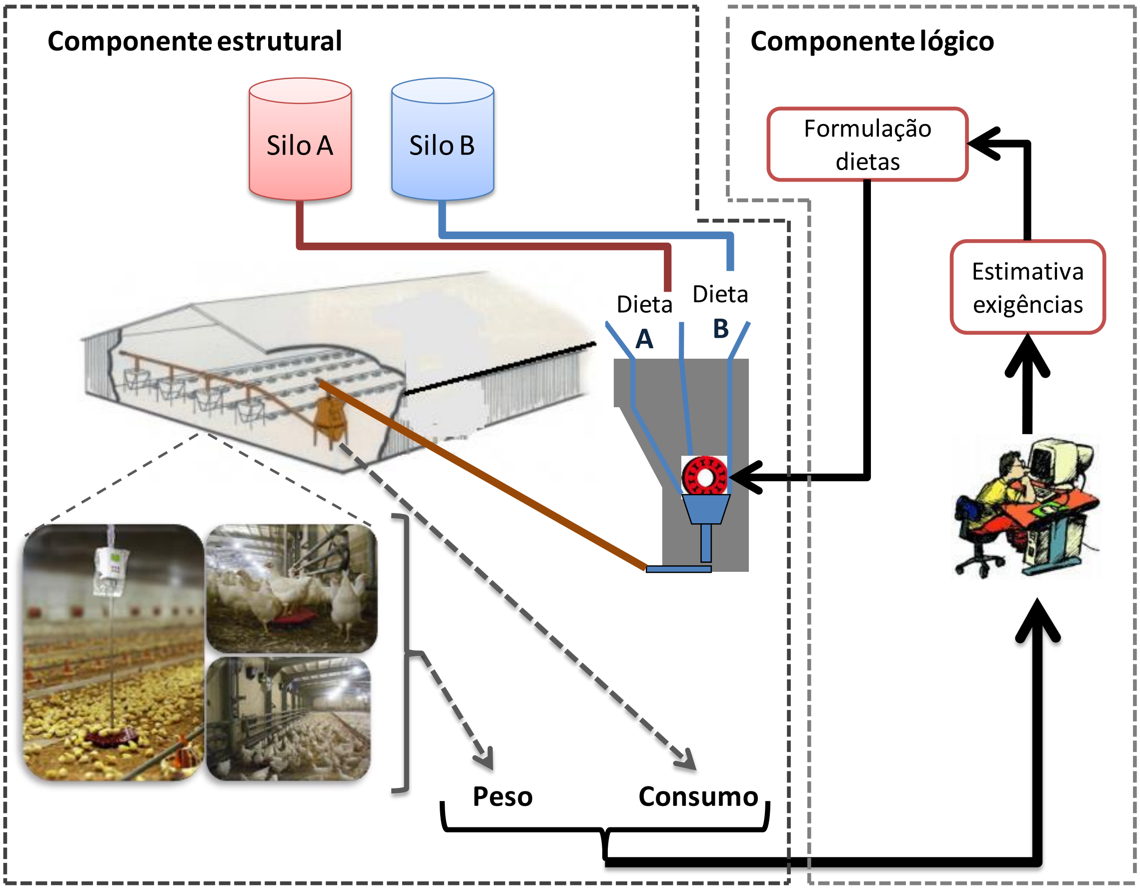

Figura 2. Representação geral de um Sistema de Nutrição de Precisão para aves com os componentes: Estrutural (balanças de pesagem das aves e do esvaziamento do silo) e Lógico (modelo matemático para estimar exigências e programa de formulação de dietas, com base em pré-misturas - A e B - que permita a formulação de dietas diariamente).

Nesse contexto, conforme evidenciado nessa revisão, os modelos atuais, por serem calibrados *a priori*, não apresentam características favoráveis para serem integradas nesse sistema de nutrição de precisão. Em suínos, um modelo em tempo real tem sido utilizado para estimar as exigências nutricionais diárias e individuais

(Hauschild et al., 2012). Esta abordagem trabalha com a estimativa dos níveis nutricionais, embasado na evolução da resposta coletada em tempo real. Em um estudo avaliando o modelo integrado em um sistema de alimentação de precisão foi possível observar melhora significativa na eficiência nutricional dos animais (Andretta et al., 2014).

Recentemente, Zuidhof et al. (2017), desenvolveram e avaliaram um alimentador de precisão para aves reprodutoras que permite a individualização da alimentação (com relação a quantidade fornecida). O sistema baseia-se no princípio de que a competição por ração dentro do lote diminui a uniformidade do PV e, consequetemente, influencia negativamente na padronização da produção de ovos. Para sua execução, o sistema faz uso de *transponders* (identificador de frequência de rádio) colocados abaixo da asa de cada animal que permite registrar informações relativas ao peso e consumo. Quando a ave apresenta peso menor que o desejado, o alimentador de precisão aumenta o aporte de alimento. A viabilidade deste sistema para aves reprodutoras está sendo avaliada. Contudo, considerando o custo decrescente da tecnologia ao longo do tempo, bem como a crescente preocupação em torno de questões que envolvem a aplicação de tecnologias de precisão na criação animal, apresenta um futuro promissor. No contexto da produção de frangos de corte, entretanto, onde o número de aves alojadas por galpão é elevado, o retorno líquido com uso de identificação individual ainda é baixo, tornando o uso desta tecnologia inviável.

Para frangos de corte foi desenvolvido um modelo de crescimento semi-mecanicista, com base em princípios teóricos e modelos anteriormente estabelecidos, em que o crescimento é estimado com base no consumo e na composição da dieta (Stacey et al., 2004). Em uma primeira etapa o modelo tem como objetivo ajustar o crescimento com base em dados da população referência. Esta etapa é realizada por meio da otimização de um parâmetro comum de crescimento pré-definido (ex: unidade de mantença). Dessa forma, é determinado o programa nutricional a ser seguido para a fase alimentar em questão pela otimização da composição das rações, e um ajuste do consumo para minimizar o erro quadrático médio entre o crescimento observado na população referência e a população alvo (potencial genético). Embora a abordagem em questão seja eficiente, é considerada complexa por demandar inúmeros parâmetros a serem calibrados no modelo. Isso torna o sistema de difícil aplicabilidade em uma condição comercial. Outro aspecto negativo é que esta abordagem tenta seguir uma trajetória pré-definida estimada com base em dados retrospectivos. O uso de um modelo como o proposto por Hauschild et al. (2012), além de preciso, é aplicável em diferentes condições de produção. Outro aspecto importante é que estes modelos representam a resposta real e não tentam seguir uma trajetória pré-definida. Nesse sentido, o desenvolvimento de um modelo matemático capaz de estimar crescimento e exigências nutricionais considerando a dinâmica do crescimento e variabilidade da população permitirá um avanço dentro do conceito de nutrição de precisão para frangos.

2.3. Problemas da pesquisa

Na revisão de literatura foram evidenciados dois problemas, os quais estão descritos resumidamente na sequência:

1) O estabelecimento de programas nutricionais para uma população específica, levando em consideração a resposta média e variabilidade do consumo e peso corporal coletados em tempo real permite avançar para o conceito de nutrição de precisão para frangos de corte. Adventos tecnológicos permitem monitorar o consumo de ração e peso vivo médio de um um lote de frangos de corte. Portanto, a variabilidade para o consumo em uma condição comercial não pode ser determimada, representando um desafio a ser superado.
2) Na produção animal, modelos de crescimento têm sido utilizados para estimar as exigências de uma população com base em um único indivíduo (fatorial) ou da resposta da população (dose resposta). Essas respostas de indivíduos e população são estabelecidas a partir de informações coletadas previamente de populações com pouca variabilidade. Nesse contexto, esses modelos estimam exigências nutricionais de um grupo de animais com base na suposição de que o potencial desses animais são similares na população referência.

2.4. Objetivos e estrutura da tese

O objetivo deste trabalho, o qual está subdividido em dois capítulos, foi:

Capítulo 2. Desenvolver um método para estimar variabilidade do consumo de ração de uma população de frangos de corte a partir de variáveis passíveis de mensuração em tempo real;

Capítulo 3. Desenvolver e validar um modelo matemático que permita estimar as exigências em aminoácidos em tempo real para um lote comercial de frangos de corte.

3. REFERÊNCIAS

ANDRETTA, I. et al. Environmental impacts of precision feeding programs applied in pig production. **Animal**, v. 12, n. 9, p. 1990-1998, 2017.

ANDRETTA, I. et al. The impact of feeding growing–finishing pigs with daily tailored diets using precision feeding techniques on animal performance, nutrient utilization, and body and carcass composition. **Journal of Animal Science,** v. 92, n. 9, p. 3925-3936, 2014.

AYDIN et al. A novel method to automatically measure the feed intake of broiler chickens by sound technology. **Computers and Electronics in Agriculture**, v. 101, p. 17-23, 2014.

BLACK, J. L.; CAMPBELL, R. G.; WILLIAMS, I. H. et al. Simulation of energy and amino acid utilisation in the pig. Research and Development in Agriculture, v.3, p.121-145, 1986.

BROSSARD, L. et al. Modelling the variation in performance of a population of growing pig as affected by lysine supply and feeding strategy. **Animal,** v. 3, n. 08, p. 1114-1123, 2009.

BUTERI, C. et al. Effects of different nutritional plans on broiler performance. **Revista Brasileira de Ciência Avícola,** v. 11, n. 4, p. 225-234, 2009.

EFG. **Broiler growth model (version 6), Broiler nutrition optimiser (version 1), Pig growth model (version 2) and Pig nutrition optimiser (Version 1).** 2006. Disponivel em: www.efgsoftware.net. Acesso em: janeiro de 2018.

EMMANS, G.C. A model of the growth and feed intake of *ad libitum* fed animals, particularly poultry. In: **Computers in Animal Production**. pp.103-110. Occasional Publication No. 5. British Society of Animal Production. 1981.

FISHER, C.; MORRIS, T.R.; JENNINGS, R.J. A model for the description and prediction of the response of laying hens to amino acid intake. **British Poultry Science**, v.14, p.469-484, 1973.

FULLER, M. F. **The encyclopedia of farm animal production.** Wallingford, Oxon, UK: CABI Pub. 620p. 2004.

FULLER, M. F.; CHAMBERLAIN, A. G. Protein requirements of pigs. In: HARESIGN, W. Protein requirements of pigs. In: HARESIGN, W. Em: **Recent Advances in Animal Nutrition**. Ed. London, U.K.: Butterwoths, p. 175-186, 1982.

GREEN, D.; WHITTEMORE, C. Architecture of a harmonized model of the growing pig for the determination of dietary net energy and protein requirements and of excretions into the environment (IMS Pig). **Animal science-glasgow then penicuik.** v. 77, n. 1, p. 113-130, 2003.

HAUSCHILD, L. et al. Multiphase feeding program for broilers can replace traditional system. **Scientia Agricola**, v. 72, n. 3, p. 210-214, 2015.

HAUSCHILD, L. et al. Development of sustainable precision farming systems for swine: estimating real-time individual amino acid requirements in growing-finishing pigs. **Journal of Animal Science,** v. 90, n. 7, p. 2255-2263, 2012.

HAUSCHILD, L.; POMAR, C.; LOVATTO, P. Systematic comparison of the empirical and factorial methods used to estimate the nutrient requirements of growing pigs. **Animal,** v. 4, n. 05, p. 714-723, 2010.

INRAPORC. **Un outil pour évaluer des stratégies alimentaires chez le porc**. Versão 1.0.4.0. INRA-UMR SENAH. 2006.

NAHM, K. Efficient phosphorus utilization in poultry feeding to lessen the environmental impact of excreta. **World's Poultry Science Journal,** v. 63, n. 04, p. 625-654, 2007.

PARSONS, D. J. et al. Real-time control of pig growth through an integrated management system. **Biosystems engineering,** v. 96, n. 2, p. 257-266, 2007.

PATIENCE, J. F.; THACKER, P. A.; DE LANGE, C. F. M. **Swine nutrition guide.** Saskatoon, Saskatchewan, Canada: University of Saskatchewan, Prairie Swine Center, 1995.

POMAR, C. et al. Applying precision feeding techniques in growing-finishing pig operations. **Revista Brasileira de Zootecnia,** v. 38, n. SPE, p. 226-237, 2009.

POMAR, C. et al. Modeling stochasticity: Dealing with populations rather than individual pigs. **Journal of Animal Science,** v. 81, n. sE. Suppl. 2, 2003.

SANTOS, L. S. et al. Precision feeding strategy for growing pigs under heat stress conditions. **Journal of Animal Science**, v.x, n.x, p. x-x, 2018.

STACEY, K. F. et al. An automatic growth and nutrition control system for broiler production. **Biosystems engineering**, v. 89, n. 3, p. 363-371, 2004.

TURNER, M. et al. An automatic weighing system for poultry. **Journal of Agricultural Engineering Research,** v. 29, n. 1, p. 17-24, 1984.

VAN MILGEN, J. et al. InraPorc: A model and decision support tool for the nutrition of growing pigs. **Animal Feed Science and Technology,** v. 143, n. 1, p. 387-405, 2008.

WATHES, C. M. et al. Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? **Computers and Electronics in Agriculture,** v. 64, n. 1, p. 2-10, 2008.

WHITTEMORE, C. T. Impact of technological innovation in animal nutrition. Livestock Production Science, v.72, p.37-42, 2001.

ZIMMERMAN, P. H.; KOENE, P.; HOOFF, J. A. R. M. The vocal expression of feeding motivation and frustration in the domestic laying hen. **Applied Animal Behaviour Science**, v. 69, p. 265-273, 2000.

ZUIDHOF et al. Precision feeding: Innovative management of broiler breeder feed intake and flock uniformity. **Journal of Poultry Science**, v. 96, p. 2254-2263, 2017.

CAPÍTULO 2 - ESTIMATIVA DA VARIABILIDADE DO CONSUMO DE RAÇÃO PARA FRANGOS DE CORTE EM CONDIÇÕES COMERCIAIS

1. RESUMO

Atualmente equipamentos tecnológicos estão disponíveis para monitorar peso médio e variabilidade (desvio padrão) em populações de frangos de corte. Porém, para consumo de ração (CR), existem apenas equipamentos que possibilitam o monitoramento médio do lote. Considerando-se que o peso corporal e o consumo de ração são variáveis correlacionadas, o objetivo do presente trabalho foi desenvolver uma metodologia que permita estimar a variabilidade do CR utilizando dados referentes à média de peso vivo (PV) e sua variabilidade (desvio padrão). Para tanto, foram utilizadas bases de dados oriundos de dois estudos, totalizando 3.032 aves subdividas em 150 unidades experimentais. Os dados de PV médio foram obtidos por meio de pesagem, semanalmente, e de CR a cada 3 dias, a partir das sobras de ração. O consumo de ração acumulado (CRA) foi obtido pela soma do CR. Os dados de cada box foram ajustados por equação polinomial quadrática para estimar o CRA e PV diário de cada box. Posteriormente, média e desvio amostral diários de CRA e PV foram calculados. A covariância e correlação amostral foram calculadas e a covariância populacional estimada. Os valores estimados de covariância e correlação para cada base foram ajustados em função do PV por meio de uma equação polinomial de segunda ordem. Foi proposta uma equação para estimar a variabilidade do CRA, com base no rearranjo da equação de correlação de Pearson. Por fim, um fator de ajuste da variabilidade do peso foi proposto, levando em consideração uma maior variabilidade existente no peso corporal das aves em condições comerciais. A acurácia das estimativas da variabilidade do CRA da metodologia proposta foi avaliada através da Média Percentual Absoluta do Erro. Os resultados demonstraram um aumento da covariância entre o CRA e PV em função do PV dos animais dentro do período estudado. O coeficiente de correlação manteve-se dentro dos limites da classificação de correlação alta, sendo considerado 0,85 para todo o período estudado. A variabilidade de CRA foi então estimada com base na equação proposta, apresentando média percentual absoluta do erro de 3,59%, quando comparado com

os dados observados. A metodologia proposta permitiu estimar a variabilidade do consumo de ração acumulado ao longo do período de crescimento com base em dados de peso vivo.

2. INTRODUÇÃO

Uma das principais preocupações na nutrição animal refere-se à estimativa das exigências nutricionais considerando o atual estado fisiológico dos animais. O consumo de ração (CR) e peso vivo (PV) dos animais, embora consideradas variáveis empíricas, representam o atual estado dos animais. Essas variáveis têm sido utilizadas como *inputs* em modelos de predição utilizados para estimar a concentração nutricional ideal da dieta para otimizar respostas (desempenho, econômica, etc) de um lote de frangos de corte (Leeson; Summers, 2001). Nesse contexto, quando o objetivo é otimizar a resposta da população (lote) mais importante que a média é o conhecimento da variabilidade dessas variáveis.

Atualmente equipamentos tecnológicos estão disponíveis para monitorar PV médio e variabilidade (desvio padrão). Da mesma forma, existem também equipamentos para monitorar o CR. Entretanto, devido a limitações tecnológicas e operacionais, somente o consumo médio pode ser mensurado. Dessa forma, torna-se importante encontrar alternativas para estimar a variabilidade do CR. Vautier et al. (2013), desenvolveram uma matriz de variância-covariância para cinco parâmetros que permitem descrever o consumo e peso vivo de forma estocástica em um modelo de crescimento para suínos (InraPorc). Essa matriz genérica foi desenvolvida com base em 40 diferentes populações (diferentes genéticas, ambientes e sexo) contendo em média 1200 animais cada. O uso dessa abordagem representa uma alternativa promissora para o estudo da interdependência entre CR e PV de aves. Entretanto, considerando algumas limitações práticas existentes no cenário avícola (informações individuais de consumo), torna-se necessário estudar outras alternativas que visem representar a variabilidade em populações para aves.

O PV e CR são variáveis correlacionadas (Scott, 2005). Assim, considerando-se a possibilidade de estimativa da média e variabilidade do PV em determinada população, é possível, desde que se tenha um adequado estabelecimento, utilizar valores de covariância e correlação entre essas duas variáveis para estimativa do CR. Portanto, o objetivo do presente trabalho foi desenvolver uma metodologia que permita estimar a variabilidade do CR utilizando dados médios de peso vivo e de sua variabilidade.

3. MATERIAL E MÉTODOS

3.1. Base e ajuste dos dados

Os dados utilizados foram extraídos de dois estudos. Um dos estudos avaliou o potencial de crescimento das linhagens Cobb e Ross (Gonçalves, 2017). Nesse estudo foram utilizadas 2.032 aves (machos e fêmeas) subdivididas em 90 unidades experimentais (boxes), em uma densidade de 22 aves/box. Por se tratar de duas linhagens esse estudo foi subdividido em 2 bases (Cobb e Ross). O outro estudo avaliou a influência de programas de alimentação multifases no desempenho e composição corporal de frangos de corte (Hauschild et al., 2015). Nesse estudo, foram utilizadas 1200 aves (machos e fêmeas), subdivididas em 60 unidades experimentais (box), em uma densidade de 20 aves/box. Em ambos estudos o delineamento experimental foi de blocos (PV) casualizados (DBC). As aves em ambos estudos foram criadas em ambiente termoneutro e alimentadas com dietas que atendiam às exigências nutricionais.

Durante o período experimental (42 dias), as aves foram pesadas semanalmente, para cálculo do PV médio, e as sobras de ração mensuradas a cada 3 dias para estimativa do CR médio. O consumo acumulado (CRA) foi obtido pela soma do CR.

Os dados de CRA e PV de cada box foram tabulados em uma planilha eletrônica. Posteriormente os dados de cada box foram ajustados utilizando uma equação polinomial quadrática a qual foi utilizada para estimar o CRA e PV diário de cada box. A partir dos dados ajustados, a média e desvio amostral diários de CRA e PV foram calculados.

3.2. Premissas adotadas

Devido a indisponibilidade de dados de consumo e PV individual foi estimado parâmetros populacionais (covariância e correlação) a partir de dados amostrais (base de dados). O uso dessa abordagem foi realizado com base em duas premissas: (1) não existe efeito do box (ambiente) e (2) e as aves dentro de cada box apresentam potencial de consumo e crescimento similares. Dessa forma, a variabilidade populacional é oriunda das diferenças de potencial de consumo e crescimento médio entre os boxes. Essas diferenças são atribuidas as diferentes categorias de peso oriundas do DBC aplicado nos estudos utilizados como base de dados. Embora a primeira premissa seja de fácil aceitação, a segunda deve ser considerada com maior cautela. Isso está relacionado ao fato que embora dentro de cada box as aves apresentaram PV similares no inicio do crescimento, os potenciais de consumo e crescimento podem ter sido distintos entre as aves. Contudo, nesse proposta assume-se que a variação intra box na respostas das aves é baixa.

3.3. Estimativa da covariância e correlação

Inicialmente, a covariância amostral ($COV\ddot{x},\ddot{y}$) existente entre os dados de CRA e PV (equação [1]) dos boxes foi calculada e para estimativa da covariância populacional a partir desses dados foi considerado que, na abordagem do presente estudo, a aplicação da equação de desvio padrão (DP) populacional implicou que a correlação entre CRA e PV mensurada entre os boxes foi a mesma mensurada entre os indivíduos dentro de um box.

$$COV_{X,Y} = \frac{\sum_{i=1}^{n}(x_i - \bar{x}) \times (y_i - \bar{y})}{n-1} \qquad [1]$$

Logo, para a correlação ser a mesma, a covariância entre os indivíduos ($COVx,y$) foi calculada pela multiplicação da covariância entre os boxes ($COV\ddot{x},\ddot{y}$) multiplicado pelo número (n=20) de animais dentro do box :

$$\mathrm{COVx,y} = \mathrm{COV}\ddot{x},\ddot{y} * \mathrm{n} \qquad [2]$$

Considerando-se que a correlação é uma medida adimensional que, assim como a média, não varia entre amostras e população, a correlação populacional entre as variáveis CRA e PV foi calculada de acordo com a Equação de Correlação de Pearson:

$$r_{x,y} = \frac{\sum_{i=1}^{n}(x_i - \bar{x}) \times (y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x}) \times \sum_{i=1}^{n}(y_i - y)}} \quad [3]$$

Assim, foi possível estimar a covariância e correlação populacionais com base em dados amostrais.

As análises de covariância e correlação foram realizadas por intermédio do Software de análise estatística SAS (version 9.3; SAS Institute, Inc. Cary, NC) pelos procedimentos PROC ANCOVA e PROC CORR, respectivamente.

3.4. Estimativa da variabilidade do consumo de ração acumulado em função do peso vivo

Os valores estimados de covariância e correlação para cada base foram ajustados em função do PV por meio de uma equação polinomial de segunda ordem. Por fim, foi proposto uma equação para estimar a variabilidade do CRA, com base no rearranjo da equação de correlação de Pearson. A correlação foi substituída pelo parâmetro de interesse, o DP CRA:

$$\text{DP CRA} = \sqrt{\frac{\text{cov (CRA,PV)}^2}{\text{corr (CRA,PV)}^2 \times (\text{DP PV})^2}} \quad [4]$$

Nessa equação além dos valores estimados de covariância e correlação entre PV e CRA é necessário também integrar o desvio padrão da população para PV. Na estimativa do DP foi assumido que, em populações suficientemente grandes, o Erro Padrão da Média (EP) é igual ao DP populacional (Lee, 2015). Assim, o EP pode ser estimado pelo desvio padrão dividido pela raiz quadrada do tamanho da amostra (EP = σ/√n), logo:

$$DP = EP * \sqrt{n} \qquad [5]$$

3.5. Fator de ajuste da Covariância

A equação [2] pode não ser adequada para situações onde a variabilidade do PV é maior comparada a uma condição experimental, tal como em condições comerciais. Isso está relacionado ao fato de que o valor da cov (CRA,PV) utilizada na equação [2] é uma constante estimada em função do peso médio do lote enquanto que o denominador (DP PV) pode variar de acordo com as condições de criação (ex: temperatura, desafios sanitários, etc). Com o objetivo de ajustar esse aspecto, foi proposto um fator de ajuste para a covariância. Esse ajuste consistiu inicialmente em propor uma equação para estimar um coeficiente de variação de referência (CV ref). O CV ref foi estimado ajustando os dados de coeficientes de variação (CV) do PV em função do PV com uso de função polinomial quadrática.

$$\mathrm{CV\ ref}_{t+1} = 3{,}4531069 + 0{,}0026319 \times \mathrm{PV}_{t+1} - 0{,}0000003 \times \mathrm{PV}_{t+1}{}^{2} \qquad [6]$$

Por fim, o Fc é estimado calculando a relação entre CV do PV observado no lote atual e o CV ref:

$$\mathrm{Fc} = \frac{\mathrm{CV\ PV}}{\mathrm{CV\ ref}} \qquad [7]$$

A relação entre CV PV e CV ref permite estimar um fator de correção (Fc) a ser aplicado na equação de covariância, de modo que a equação [3] passa a ser aplicada da seguinte forma:

$$\mathrm{DP\ CRA} = \sqrt{\frac{(\ \mathrm{cov(CRA,PV)} \times \mathrm{Fc})^2}{\mathrm{corr(CRA,PV)}^2 \times (\mathrm{DP\ PV})^2 \times \mathrm{var(PV)}}} \qquad [8]$$

3.6. Avaliação da metodologia proposta

A acurácia das estimativas de DP CRA da metodologia proposta foi avaliada através da Média Percentual Absoluta do Erro (MAPE - Mean Absolute Percentage Erro):

$$\mathrm{MAPE}, \% = \frac{\sum\left|\frac{y_t - \hat{y}_t}{y_t}\right|}{n} \times 100, (y_t \neq 0) \qquad [9]$$

Onde y_t é o valor observado no tempo t e $\hat{y}_t$ é o valor estimado pela equação [8]. Os dados observados são esses obtidos da base de dados.

RESULTADOS E DISCUSSÃO

Os resultados das estimativas da covariância entre PV e CRA em função do PV estão apresentados na figura 1. Os resultados demonstram um aumento ($cov_{CRA,PV} = 0,001 \times PV^{2,86425}$ r^2=0,99) da covariância entre o consumo e peso em função do PV dos animais dentro do período estudado.

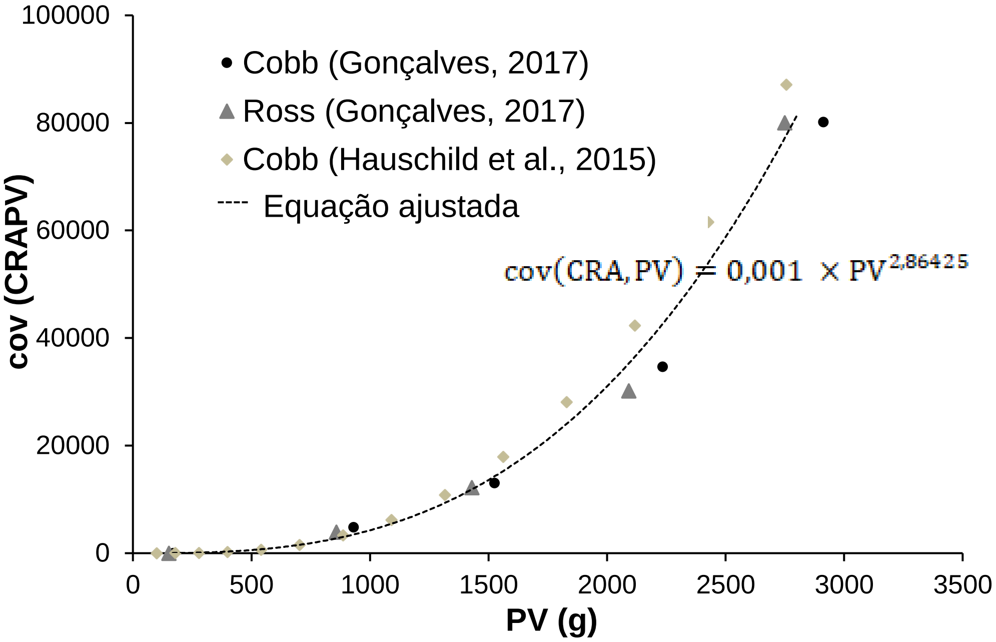

Figura 1. Covariância entre Consumo de Ração Acumulado e Peso Vivo - cov (CRA,PV) - em função do Peso Vivo (PV) de três diferentes estudos conduzidos com as linhagens *Cobb* e *Ross* no período de 7 a 42 dias de idade, ajustados pela equação covCRA,PV = 0,001 x $PV^{2,86425}$ (r^2=0,99).

A alta relação entre PV e CRA era esperada, considerando-se a interdependência entre as duas variáveis. Um aspecto importante a ser mencionado é que o ajuste da equação foi realizado utilizando uma base de dados pequena. Entretanto, considerou-se neste estudo as duas principais linhagens comerciais de crescimento utilizadas atualmente em meio comercial e, portanto, as mais representativas.

O mesmo procedimento foi realizado para correlação (corrCRA,PV), tal como pode ser observado na Figura 2. Embora a covariância aumentou ao longo do tempo, a correlação apresentou pouca variação ao longo do período simulado. A covariância embora permita descrever a variância entre duas variáveis aleatórias não possibilita determinar a real interdependência entre as variáveis. Dessa forma a normalização da covariância, traduzida pela correlação, permite que seja realizada de fato uma comparação representando grandezas diferentes. O aumento exponencial da covariância está relacionado ao aumento da variabilidade do CRA e PV em função da idade das aves. Esse comportamento tem sido observado em outros estudos com aves (SCOT, 2005), como também em meio comercial (COBB, 2017). Contudo, a correlação é a covariância normalizada, não sofrendo a influência das unidades podendo ou não ser constante ao longo do tempo.

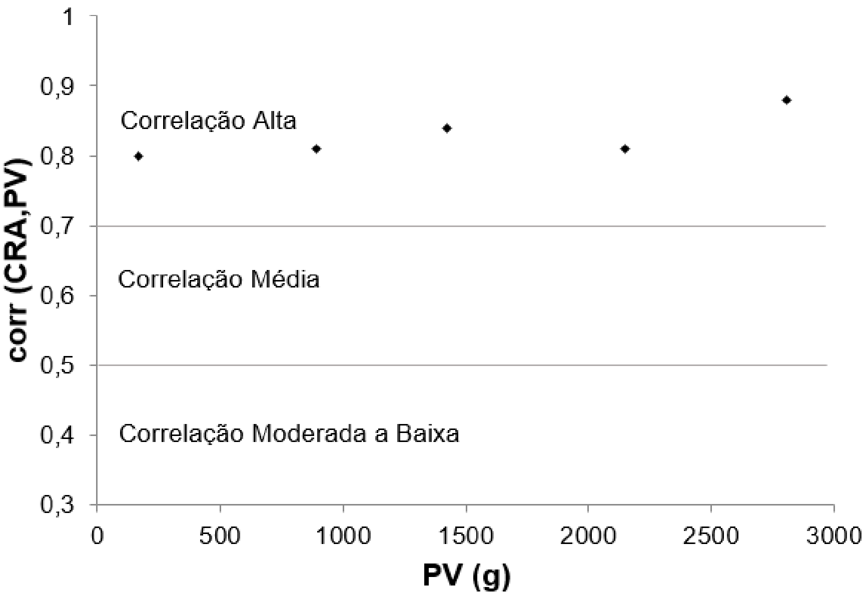

Figura 2. Correlação entre Consumo de Ração Acumulado e Peso Vivo - corr (CRA,PV) - em função do Peso Vivo (PV) estimado com base em dados obtidos de 3 diferentes estudos conduzidos com as linhagens *Cobb* e *Ross* no período de 7 a 42 dias de idade.

De modo geral, considera-se, com relação ao coeficiente de correlação Pearson, valores altos acima de 0,7; valores médios entre 0,5 e 0,7 e valores baixos abaixo de 0,5 (Mukaka, 2012). Tal como observado na Figura 2, o coeficiente de correlação ao longo do período estudado manteve-se dentro dos limites da classificação de correlação alta. Por isso, foi realizada uma média entre as correlações calculadas para cada período e estabelecido o valor constante 0,85 de corr(PV,CRA) ao longo de todo o período de crescimento.

Por fim, a partir da covariância e correlação estimadas e através do reajuste da equação de correlação de Pearson é possível estimar a variabilidade do CRA. Nessa abordagem a escolha das variáveis de estado (PV e CRA) ao invés de variáveis de taxa (ganho de peso e consumo de ração diário) deve-se ao fato de que atualmente com os equipamentos disponíveis não é possível a estimativa da variabilidade de variáveis de taxa em condição comercial. Contudo, de acordo com a metodologia proposta, a variabilidade de CRA pode ser estimada com uma boa precisão (Figura 3), apresentando média percentual absoluta do erro de 3,59%, quando comparado com os dados observados. De qualquer forma, maiores estudos devem ser realizados para estudar o comportamento da variabilidade do consumo em condições de desafios nutricional, ambiental e sanitário.

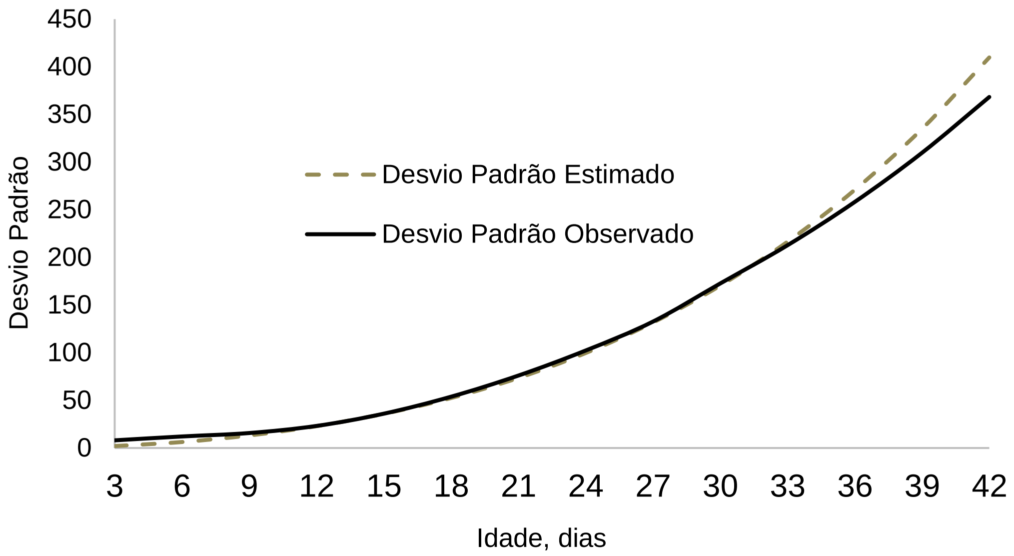

Figura 3. Desvio Padrão observado e o estimado a partir da equação que estima a variabilidade do Consumo de Ração Acumulado (CRA) com base nos dados de variabilidade do Peso Vivo (PV), covariância e correlação entre as variáveis CRA e PV.

4. CONCLUSÕES

A metodologia proposta permite estimar a variabilidade do consumo de ração acumulado ao longo do período de crescimento com base em dados de peso vivo. Maiores estudos, entretanto, devem ser realizados para avaliar a interdependência entre o consumo e o crescimento de frangos de corte em condições de desafio nutricional, ambiental e sanitário.

5. REFERÊNCIAS

COBB Vantress Brasil. **Manual de Manejo de Frangos de Corte**. 2017, 74p.

GONÇALVES, C. A. **Modelagem do crescimento, composição do corpo e das penas em frangos de corte**. 2017. Tese (Doutorado em Zootecnia), Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista UNESP, Jaboticabal, 2017.

HAUSCHILD, L. et al Multiphase feeding program for broilers can replace traditional system. **Scientia Agricola**. v. 72, n.3, p. 210-214, 2015.

LEE, D.; KYU, J.; SANGSEOK, L. Standard deviation and standard error of the mean. **Korean Journal of Anesthesiology**. v. *68, n.* 3, p.220-223, 2015.

LEESON, S.; SUMMERS, J.D. **Nutrition of the chicken**. 4.ed. Ontario: University Books, 2001. 413p.

MUKAKA, M.M. Statistics Corner: **A guide to appropriate uso of Correlation coefficient in research**. v. 24, n. 3, p. 69-71, 2012. Malawai Medical Journal. 2012.

SCOTT, T. A. Variation in feed intake of broiler chicks. **Recent advances in Animal Nutrition in Australia**. v. 15, p. 237-244, 2005.

VAUTIER, B. et al. Accounting for variability among individual pigs in deterministic growth models. **Animal**. v. 7, n. 8, p. 1265-1273, 2013.

CAPÍTULO 3 – ESTIMANTING REAL-TIME AMINO ACID REQUIREMENTS IN A BROILER FLOCK

Capítulo formatado de acordo com as Normas da Revista *Poultry Science*

Estimating real-time amino acid requirements in a broiler flock

Jaqueline de Paula Gobi,[*] Candido Pomar,[†*] Nilva Kazue Sakomura,[*] Ines Andretta,[‡] Anders Ringgaard Kristensen,[§] Aline Remus,[†] and Luciano Hauschild,[*1]

*Department of Animal Science, School of Agricultural and Veterinary Sciences (FCAV), São Paulo State University (UNESP), Jaboticabal, São Paulo, Brazil, 14883-108

[†] Sherbrooke Research and Development Centre, Agriculture and Agri-Food Canada, Sherbrooke, Québec, Canada, J1M 0C8

[‡] Department of Animal Science, Federal University of Rio Grande do Sul, Porto Alegre, Rio Grande do Sul, Brazil, CEP

[§]University of Copenhagen, Faculty of Health and Medical Sciences, Department of Veterinary and Animal Sciences, Grønnegårdsvej 2, Frederiksberg C, Denmark. DK 1870.

[1]*Corresponding author: luciano.hauschild@unesp.br (Luciano Hauschild;* Department of Animal Science, School of Agricultural and Veterinary Sciences (FCAV), São Paulo State University (UNESP), Jaboticabal, São Paulo, Brazil, 14883-108; Telephone: +55 (16) 3209-7443)

Scientific section: Metabolism and Nutrition

ABSTRACT: A mathematical model with empirical (**EC**) and mechanistic components (**MC**) was developed to estimate daily amino acid (**AA**) requirements of a broiler flock. The EC estimates Daily Feed Intake (**DFI**), Daily Gain (**DG**), BW, and Cumulative DFI (**CuFI**, mean and SD) for the next day based on broiler flock information collected in real time (DFI, DG, and SD of BW). Based on the SD of BW and SD of CuFI estimates, the relative variability of feed efficiency (**RelVarEff**) is estimated. Then, the MC uses factorial equations to estimate the optimal concentration of AA that must be offered to the broiler flock (average and percentiles). The model was evaluated with data from a study that investigated the effect of feeding broiler with a multiphase system. The DFI, DG, and CuFI (SD) values measured in this study were compared with those estimated by the EC. The ability of the model to estimate the AA requirement for flocks with different heterogeneity was evaluated by simulating conditions with lower and higher variability. Lastly, the proposed model was evaluated by comparing its estimates with those generated by an existing growth model (Avinesp). The precision of proposed model and Avinesp in estimating DFI, DG, and SD of CuFI was evaluated through the mean absolute error (**MAPE**). The DFI, DG, and SD of CuFI (Lower variability) trajectories of broiler flock could be predicted 3 d ahead with MAPE of 2.91, 2.20, and 3.59%, respectively. The MAPE obtained with Avinesp was 4.32% for DFI and 6.67% for DG. The average dietary standardized ileal digestible lysine (**SIDLys**) concentration estimated by the proposed model was similar to the values obtained by Avinesp (1.09 *vs* 1.08%). However, only the proposed model allowed estimating the SIDLys requirement for the percentile 80th of the flock (1.17% for Lower variability and 1.24% for Higher variability). Based on recursive modeling, RelVarEff estimates and using factorial equation, the model estimates dynamically the AA requirements for broilers taking into account the flock heterogeneity.

Key words: amino acid, mathematical modeling, precision poultry nutrition, variability

INTRODUCTION

Feed costs account for at least 60% of poultry production costs, and a feed system that promotes better feed efficiency results in smaller ecological footprint (Castellini et al., 2012). Therefore, methods that allow improving the accuracy of nutritional requirements should be used to achieve these different objectives in production, especially to maximize nitrogen retention. Growth models (Sakomura et al., 2005, Dorigam et al., 2014, Rostagno et al., 2017) using the factorial method has been used to estimate the requirements of an individual that is representative of the population. Despite their effectiveness, these growth models (e.g., Avinesp; Hauschild et al., 2014) must be properly calibrated in relation to a past reference population to ensure that the levels of nutrients needed to optimize animal responses are accurately estimated. Hence traditional models are challenged by the difficulty of identifying an adequate reference population for the calibration. Furthermore, animals from actual populations may follow different growth patterns from the ones observed in the reference populations. Therefore, real-time models (Aerts et al., 2003; Stacey et al., 2004) have been proposed aiming to simulate complex biological responses and, to control of flock growth favoring uniformity. Though these models can fairly predict real-time growth, they are not able to provide a daily personalized feed to meet amino acids (**AA**) requirements for each broiler flock. To solve this problem, a precision feeding approach can be proposed.

Precision livestock farming is a concept that relies on the existence of variability intra and inter animals and production units (Wathes et al., 2008). Precision livestock feeding (**PLF**) is part of precision livestock farming and can have a great impact in livestock profitability due the ability of feeding animals with diets tailored daily to their nutrient requirements (Pomar et la., 2019). The PFL concept can be applied due the availability of nutrition management technology to monitor feed intake (mean) and BW (mean and SD) and also to provide diets adjusted daily for a broiler flock (Frost et al., 2003). Thus, the use of PLF for broiler flocks allows the right amount of feed with the right composition to be provided each day in order to optimize the flock response. However, that system requires the continuous assessment of nutrient requirements of each broiler flock on the basis of its own patterns of feed intake and growth (mean and variation). Accordingly, the purpose of this study was to develop and evaluate a mathematical model, in which an empirical and a mechanistic component are used to estimate in real-time standardized ileal digestible lysine (**SIDLys**) requirements and optimal dietary AA concentration for a broiler flock as required for the implementation of precision feeding systems in commercial broiler farms.

MATERIAL AND METHODS

Model Development

General Description

The proposed model estimates daily AA requirements and their optimal dietary concentrations for a broiler flock according to its actual daily gain (**DG**), daily feed intake (**DFI**), and SD of BW (**SD BW**). This model follows a similar approach to that described by Hauschild et al. (2012), combining empirical and mechanistic components (Figure 1) that result in a “grey-box” model (Roush, 2006).

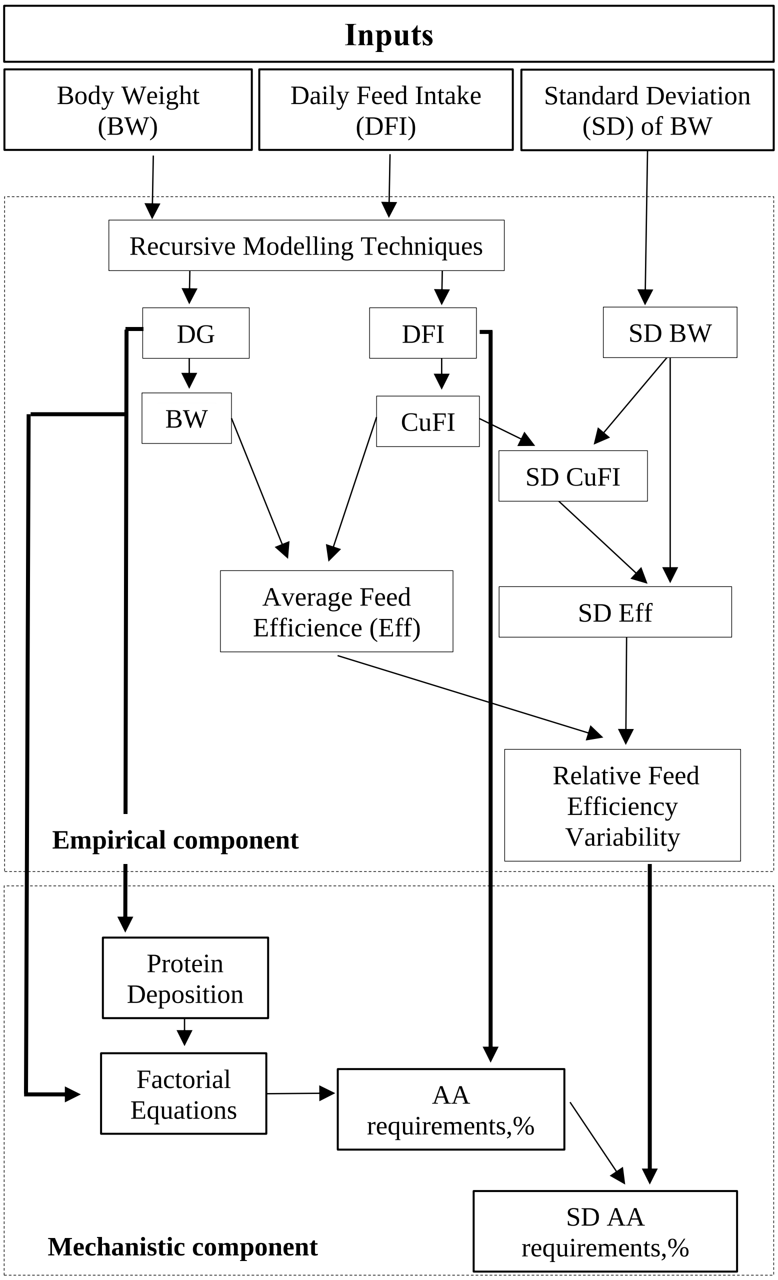

Figure 1. General outline of the model with empirical and mechanistic components used to estimate daily requirements for a broiler flock according to their actual growth and feed intake patterns.

In the empirical model component, DG and DFI are estimated for the starting day using daily-calibrated equations based on historical up-to-date information (DG and DFI of the flock). Based on the SD BW, relative variability of feed efficiency (**RelVarEff**) is estimated. In the mechanistic model component, the BW, DG, and DFI are the driving variables used in a factorial procedure, estimating the average AA requirements of a broiler flock (average requirement). Finally, the optimal nutritional level to meet the requirements for different proportions of the population (e.g., percentile 80th, 90th, etc.) is estimated based on the average AA requirement and RelVarEff.

Rate variables are expressed on a daily basis, masses in grams (DFI and DG) and milligrams (SIDLys requirements), and concentrations in percentages. The provisions and requirements of SIDLys are expressed in concentration of the diet (i.e., SIDLys, %), whereas the other amino acids are calculated in ratio to SIDLys (Rostagno et al., 2017). Other nutrient requirements, including minerals or vitamins, are not estimated by this model. Time is expressed in days and real-time simulation refers in this study to a model that executes at daily clock time. Time t is the current day and m indicate the number of days ahead to be predicted.

Empirical Model Component

The empirical component of the model is used to estimate current-day DFI and DG from the information measured in the population up to time $t + m$, where m=1. The BW and cumulative feed intake (**CuFI**) are calculated based on DG and DFI estimates.

Modelling the feed intake and growth – Univariate Dynamic Linear Model (DLM) and Kalman filter

An approach that follows in real time the performance trajectory of the broiler flock is used to estimate DFI and DG of the population for the starting day (t+1). The DLM can model fluctuations over time in the underlying means, which makes it well suited for modeling the evolution in broiler's DFI and DG over time. In addition, DLM also allow forecasting DFI and DG, based on prior knowledge including former observations. The following DLM description is mainly based on West & Harrison (1997) and has a structure similar to those developed by Madsen et al. (2005), except for the absence of a diurnal cyclic component.

The DLM consists of an observation equation and a system equation (Equations [1] and [2], respectively) as follows:

$$Y_t = F'\theta_t + v_t,\ v_t \sim N(0, V_t)\ [1]$$

$$\theta_t = G\theta_{t-1} + w_t,\ w_t \sim N(0, W_t)\ [2]$$

where $\mathbf{Y}_t$ is the observation vector (DFI or DG), $\mathbf{F'}_t$ is the transposed design matrix, $\mathbf{v}_t$ is a random observation error, $\boldsymbol{\theta}_t$ is the unobservable parameter vector, $\mathbf{V}_t$ is the observational covariance matrix, $\mathbf{G}_t$ is the system matrix, $\mathbf{w}_t$ is a random system evolution error, and $\mathbf{W}_t$ is the systematic covariance matrix. Equation [1] describes how the values of an observation vector (Y_t) depend on an unobservable parameter vector (θ_t) to time t. The system equation [2] describes how the parameter vector may change over time. To describe both level and trend, the parameter vector (θ_t) contains the underlying values for each of the continuous variables, as well as the trend of the variable. The G_t describes the evolution of the parameter vector θ from time t-1 to time t. The F'_t allows extracting the expected values of the observable variables from the parameter vector. The transposed design matrix has the following structure:

$$F' = [1 \quad 0]\ [3]$$

The system matrix for a local linear trend model is given as:

$$G' = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}\ [4]$$

All the information available (**Y**) at time t and also the initial information (t=0) is defined as $\mathbf{D}_t$ and it is expressed by the follow equation:

$$D_t = D_{t-1} \cup \{Y_t\} [5]$$

The Kalman filter estimates the prior distribution for θ_t, 1-step forecast distribution for Y_t, and posterior distribution for θ_t given D_t based on all information available at time $t - 1$. The mean and variance-covariance matrix of the posterior distribution are represented as $\mathbf{m}_t$ and $\mathbf{C}_t$, respectively, so that $(\theta_t|D_t) \sim N(m_t, C_t)$. In order to initialize the model, prior information is required $\mathbf{D_0}$ (before any observation are made, $t = 0$) on the initial distribution of the parameter vector $(\theta_0|D_0) \sim N(m_0, C_0)$. The observation and evolution error sequences vt and w_t are assumed to be internally and mutually independent, and are independent of $(\theta_0|D_0)$. For further details about equations updating see West and Harrison (1997).

Variance components

It seems reasonable to assume that the observational variance, is constant during the growth period, but varies between broiler flocks. This problem is solved in the model by considering a variance constant and unknown for each broiler flock time series. To achieve this the updated parameter vector θ_t is distributed according to a Student T distribution which converges to the standard normal distribution as t increases and that the estimated precision ($ø = V^{-1}$) becomes Gamma distributed. For further details see West and Harrison (1997). The system variance for DFI and DG changes as the broiler grow up. To account to this evolution error, the system variance was modeled using a discount factor ($\boldsymbol{\delta}$), as previously described by Madsen et al. (2005).

Reference analysis and discount factor

The specification of prior distributions is necessary to initialize the model. For that, the reference analysis is used to estimate the initial parameters $D_0 \sim (m_0, C_0)$ as described by West and Harrison (1997). In this model, the reference analyses use the first three observations of the series in question to estimate the parameters. The discount factor was determined according the method proposed by Kristensen et al. (2010). The objective was to estimate a discount factor in order to optimize the performance of the DLM forecast (i.e. minimizing the normalized forecast errors: $\mathbf{e}_t^{\mathbf{norm}}$). The DLM was run for a population of broilers (Hauschild et al., 2015) using different δ-values ranging from 0.1 up to 1 in increments of 0.01. The δ-value that minimized the sum of the square normalized forecast errors were chosen for this model. The forecast errors were normalized with respect to the forecast variance Q, such that $e_t^{norm} = e_t/\sqrt{Q_t}$. The optimize δ-value for DFI and DG were 0.46 and 0.27, respectively. However, to avoid greater fluctuations in the estimate DFI and consequently on the daily nutrient concentration, a higher **δ**-value (0.9) is adopted in the DLM to estimate DFI.

Estimating variability of cumulative feed intake

In order to estimate SD of CuFI (**SD CuFI**), from the assumption of interdependence between this variable and BW, an equation obtained by rearrange of the Pearson's Correlation formula is proposed:

$$\mathrm{SD\ CuFI}_{t+1} = \sqrt{\frac{\mathrm{cov}\ (\mathrm{BW}_{t+1}, \mathrm{CuFI}_{t+1})^2}{\mathrm{corr}\ (\mathrm{BW}_{t+1}, \mathrm{CuFI}_{t+1})^2 \times\ (\mathrm{SD\ BW}_t)^2}} \quad [6]$$

The application of equation [6] implies, however, that besides SD BW, it is also necessary to know the covariance and the correlation between BW and CuFI variables. Due to the inexistence of an economically feasible system that measures individual feed intake in broiler flocks, it is difficult to estimate covariance and correlation between CuFI and BW using individual information. Therefore, in this project, it was decided to consider the behavior of these statistical measures in function of the BW using information from groups of birds (pens).

Estimating Covariances and Correlations

To study the degree and magnitude of the interdependence between BW and CuFI, it was used data from a study that evaluated the growth potential of Cobb and Ross strains (Gonçalves, 2017), and another one that compared the performance of Cobb strain, reared under different feeding programs (Hauschild et al., 2015). In these studies, males and females birds were fed diets which matched nutrient requirements of each strain. The BW, fed provided and the fed waste were measured weekly from 1 to 42 days of age in both studies. Each pen was considered the experimental unit (22 birds per pen on average), totaling a database of 2032 individuals housed in 92 pens, subdivided into three groups (two Cobb and one Ross strains). Covariances between BW and CuFI (**covBWCuFI**) was estimated for each genetic group by sample data (pens) analysis, from 7 to 42 days of age. Due to the similar pattern and data homogeneity between strains and sex for covBWCuFI, only one equation was adjusted to estimate covBWCuFI in function of the BW (Figure 2). Thus, the covBWCuFI as a function of BW is estimated as follows:

$$\mathrm{covBWCuFI}_{t+1} = 0.0001 \times \mathrm{BW}_{t+1}{}^{2.86425} \quad [7]$$

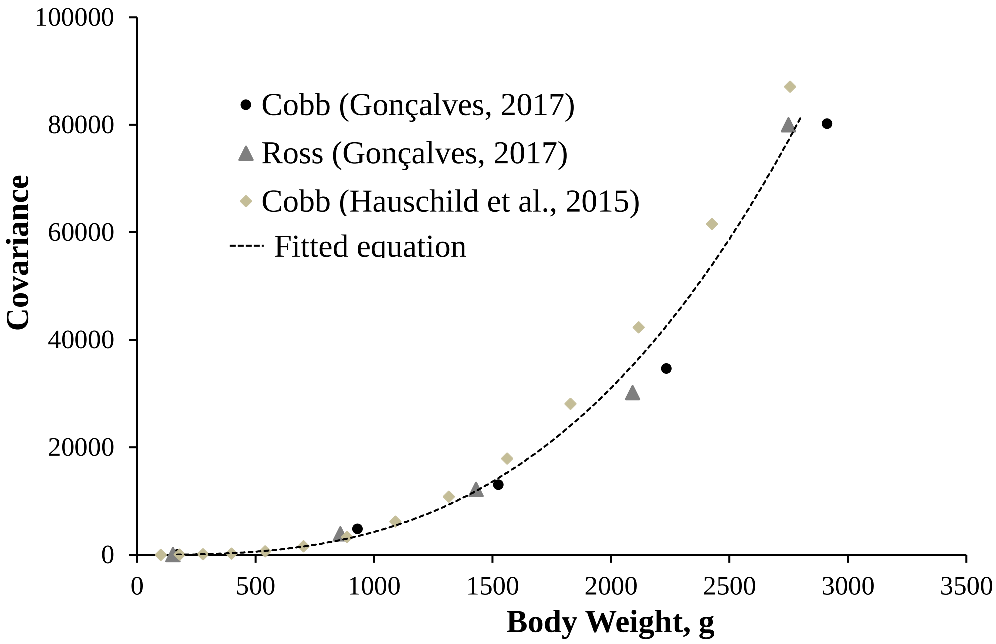

Figure 2. Fitted equation ($\mathrm{cov}BWCuFI = 0.0001 \times BW_t^{2.86425}$) according the observed data to estimate the covariance between body weight and cumulative feed intake.

Similar procedure was performed for the correlation between BW and CuFI (**corrBWCuFI**). However, because similar corrBWCuFI estimates over different BW were observed, a single value is proposed to be applied in the estimation of SD CuFI (0.85).

Covariance correction factor

Under commercial conditions, variability values (e.g., CV) are usually higher than those observed in experimental conditions (database). To account to this aspect, a correction factor (**Fc**) was proposed for CovBWCuFI. According to the database, it was possible to verify that covariance increases linearly with the increase of the BW variance - $(\text{SD BW})^2$. Thus, the proposed correction factor assumes that the CovBWCuFI will change proportionally with the increase or decrease of CV of BW (**CV BW**). To perform this adjustment, we initially determined an equation to estimate the reference variability (**CV Ref**) as a function of BW. For that, a two-order polynomial function was fitted ($r^2 = 0.99$) to the CV data as a function of the BW:

$$\text{CV ref}_{t+1} = 3.4531069 + 0.0026319 \times \text{BW}_{t+1} - 0.0000003 \times \text{BW}_{t+1}{}^{2} \text{ [11]}$$

Thus, the Fc is estimated by calculating the ratio between CV of the BW observed on the current flock and CV ref:

$$\text{Fc}_{t+1} = \frac{\text{CV BW}_{t+1}}{\text{CV ref}_{t+1}} \text{ [8]}$$

According to the proposed equations and correction factor, a final equation from the equation [9] is proposed to estimate the variability of the CuFI:

$$\text{SD CuFI}_{t+1} = \sqrt{\frac{(\text{covBWCuFI}_{t+1} \times \text{Fc}_{t+1})^2}{(\text{corrBWCuFI}_{t+1})^2 \times \ (\text{SD BW}_t)^2(\text{varBW}_{t+1})}} \text{ [9]}$$

Estimating Relative Feed Efficiency Variability (RelVarEff)

Feed or nutrient efficiency can be estimated by the relationship between BW and cumulative feed or nutrient intake (Kebreab et al., 2007). From this assumption and based on the BW (mean and SD) and CuFI (mean and SD), the average feed efficiency (**Eff**) and SD (**SD Eff**) are estimated as follows:

$$\mathrm{Eff}_{t+1} = \frac{\mathrm{BW}_{t+1}}{\mathrm{CuFI}_{t+1}} \text{ [10]}$$

$$\mathrm{SD\ Eff}_{t+1} = \mathrm{SD\ BW}_{t+1} + \mathrm{SD\ CuFI}_{t+1} - \sqrt{\mathrm{SD\ BW}_{t+1} \times \mathrm{SD\ CuFI}_{t+1} \times \mathrm{CorrBWCuFI}} \text{ [11]}$$

Then, RelVarEff is estimated by the equation as follows:

$$\mathrm{RelVarEff}_{t+1} = \frac{\mathrm{Eff}_{t+1}}{\mathrm{SD\ Eff}} \text{ [12]}$$

Mechanistic Model Component

The mechanistic model component is used to estimate current-day SIDLys requirements for the average individual of a broiler flock based on current day DFI, DG, and BW information previously estimated by the empirical model component. The requirements of other AA were stablished in ratio to SIDLys (Rostagno et al., 2017), assuming changes in requirements proportional to SIDLys changes. Finally, the optimal nutritional level to match requirements for different proportions of the population (e.g., percentile 80th, 90th, etc.) is estimated based on the average individual AA requirement and RelVarEff.

Estimating AA requirements of the average bird

The real-time protein deposition (**PD**) is estimated based on proportion of protein retained in gain (PD/DG) as suggested by Schinckel & de Lange (1996). First, protein composition (%) is estimated in function of the BW applying the allometric equation (Bertrand et al. 2013). In this study, the parameters did not differ between strains (Cobb and Ross) and sex. Thus, PD is estimated as follows:

$$\mathrm{PD/DG}_{t+1} = (\exp(1.04 \times \mathrm{Ln}(\mathrm{BW}_{t+1}) - 2.16))/\mathrm{BW}_{t+1} \text{ [13]}$$

$$\mathrm{PD}_{t+1}(\mathrm{g}) = \mathrm{DG}_{t+1} \times (\mathrm{PD/DG})_{t+1} \text{ [14]}$$

The SIDLys requirement is partitioned into maintenance and growth. The maintenance requirement (**SIDLysM**) is estimated using the equation proposed by Rostagno et al. (2011):

$$\mathrm{SIDLysM}_{t+1}(\mathrm{mg}) = 0.07 \times (\frac{\mathrm{BW}_{t+1}}{1000})^{0.75} \times 1000 \text{ [15]}$$

Then, the growth requirement (**SID LysG**) is calculated as follows:

$$\mathrm{SIDLysG}_{t+1}(\mathrm{mg}) = ((\mathrm{PD}_{t+1} \times 1000) \times \mathrm{Lys}_{\mathrm{conc}})/\mathrm{Eff}_{\mathrm{Lys}} \text{ [16]}$$

where $\mathbf{Lys_{Conc}}$ is the Lys concentration in PD and $\mathbf{Eff_{Lys}}$ is the efficiency of utilization of SIDLys for PD. These parameters are assumed to be constant throughout the entire growth period. The values used in this model are 0.069 for $\mathrm{Lys_{Conc}}$ (Stilborn et al., 2010) and 0.79 for $\mathrm{Eff_{Lys}}$ (Edwards, 1999).

The SIDLys concentration (**SIDLys,%**) of the diet is then estimated as follows:

$$\mathrm{SIDLys,\%}_{t+1} = \frac{(\mathrm{SIDLysM}_{t+1} + \mathrm{SIDLysG}_{t+1})/1000}{\mathrm{DFI}_{t+1}} \times 100 \text{ [17]}$$

Estimating requirement for different population proportions

Variability (SD) of SIDLys, % is estimated based on the equation:

$$\mathrm{SD\ SIDLys,\%}_{t+1} = \mathrm{SIDLys,\%}_{t+1} \times \mathrm{RelVarEff}_{t+1} \text{ [18]}$$

Thus, based on the SIDLys and SD of SIDLys,$\%_{t+1}$, a broiler population is generated randomly having normally distributed SIDLys requirements. Finally, the optimal level can be estimated to meet the requirement for different proportions of the population (e.g., different percentiles). Other AA requirements are estimated in relation to SIDLys, % according to an ideal AA profile adjusted for the different phases (Rostagno et al., 2017).

Model Evaluation

Data from a broiler population (n = 600) of female and male birds described by Hauschild et al. (2015) were used to evaluate the proposed model. In this study, thirty pens with 20 broilers each were used. These broilers were part of a larger project studying the effects of rearing broilers in a 4-phase or in a multiphase feeding program on growth performance, body composition, and nitrogen excretion. Broilers were fed ad libitum from 0 to 42 d of age by blending 2 premixes. The composition of the blended premixes was calculated to meet or exceed the animals' requirements throughout the growth period. Feed intake and BW were measured by weighing the feed and birds every 3 days.

In order to evaluate the model when estimating the optimal dietary amino acid concentration for a broiler flock, SD BW was estimated from the means and samples variability among the 30 boxes in the database. This proposal is based on the premise that, in large populations, the standard mean error is equal the population SD (Lee et al., 2015). For this population, the CV BW was on average 7% representing a population with low variability. In order to also have a population with high variability (CV=14%), the average SD over the period was multiplied by 2. Thus, two conditions of variability were simulated, low and high variability.

The observed DFI and DG, and SD BW (lower variability and higher variability) of the databases were used as inputs in the model. The empirical component equations were applied according to the described model, with the exception of the *m*-period-ahead (*m* = 3), due to the unavailability of daily data. In the mechanistic model component, a population of 1000 birds was randomly generated. Thus, the 3-d measurements of DFI, DG, CuFI (mean and SD), and BW values measured by Hauschild et al. (2015) were compared to those estimated by the empirical model component. The coherence of the estimated values yielded by the mechanistic model component was evaluated by analyzing whether it followed a normal pattern of requirements in accordance to other studies. Lastly, the proposed model was evaluated by comparing its estimates with those generated by the existing growth model Avinesp (Hauschild et al., 2014). This model characterizes the broiler representing a population, usually the average individual bird, on the basis of previously collected data. In this model, diet composition and broiler genotype are considered model inputs. This model is based on the transformation of dietary nutrients into body protein and lipids, which are then used to estimate bird response. The Avinesp model can be used to estimate feed intake and growth (DFI and BW) of a bird that is assumed to be the best representative of the population and to calculate the daily requirement for a given nutrient (e.g., Lys). The average bird was taken as the representative of the population, which was characterized using the same data used in the proposed model evaluation. The procedure described by Hauschild et al. (2014) was used to describe the average bird potential. The diet used in the simulation was one that met the nutrient requirements for the average bird. The Avinesp model parameters were, however, invariable over the growth period and obtained a priori using all the broiler historical data, from which 3-d interval estimates were obtained. The proposed model parameters were updated 3-d interval using up-to-date available information.

The accuracy of the proposed model for DFI, DG, and CuFI (mean and SD) estimation (comparing only with lower variability database) were assessed by the means absolute percentage error (**MAPE**), as described in the study of Roush et al. (2006):

$$\mathrm{MAPE}, \% = \frac{\sum\left|\frac{y_t - \hat{y}_t}{y_t}\right|}{\mathrm{n}} \times 100, (\mathrm{y_t} \neq 0)\ [19]$$

where $\mathbf{y_t}$ is the value observed at time $\boldsymbol{t}$ and $\hat{\mathbf{y}}_{\boldsymbol{t}}$ is the value estimated by the model.

RESULTS

Empirical Component of the Model

The empirical component of the model predicted 3 periods (m) in advance the DFI and DG trajectories of the broiler flock fed ad libitum, with an average MAPE of 2.20 and 2.91%, respectively. The Avinesp model - based on the Gompertz function - presented an average MAPE of 6.67 and 4.32% for DFI and DG, respectively (Figures 3A and 3B). Since the proposed model showed smaller errors for DFI and DG estimates compared to Avinesp, it was expected to have better estimates for CuFI and BW (Figures 4A and 4B).

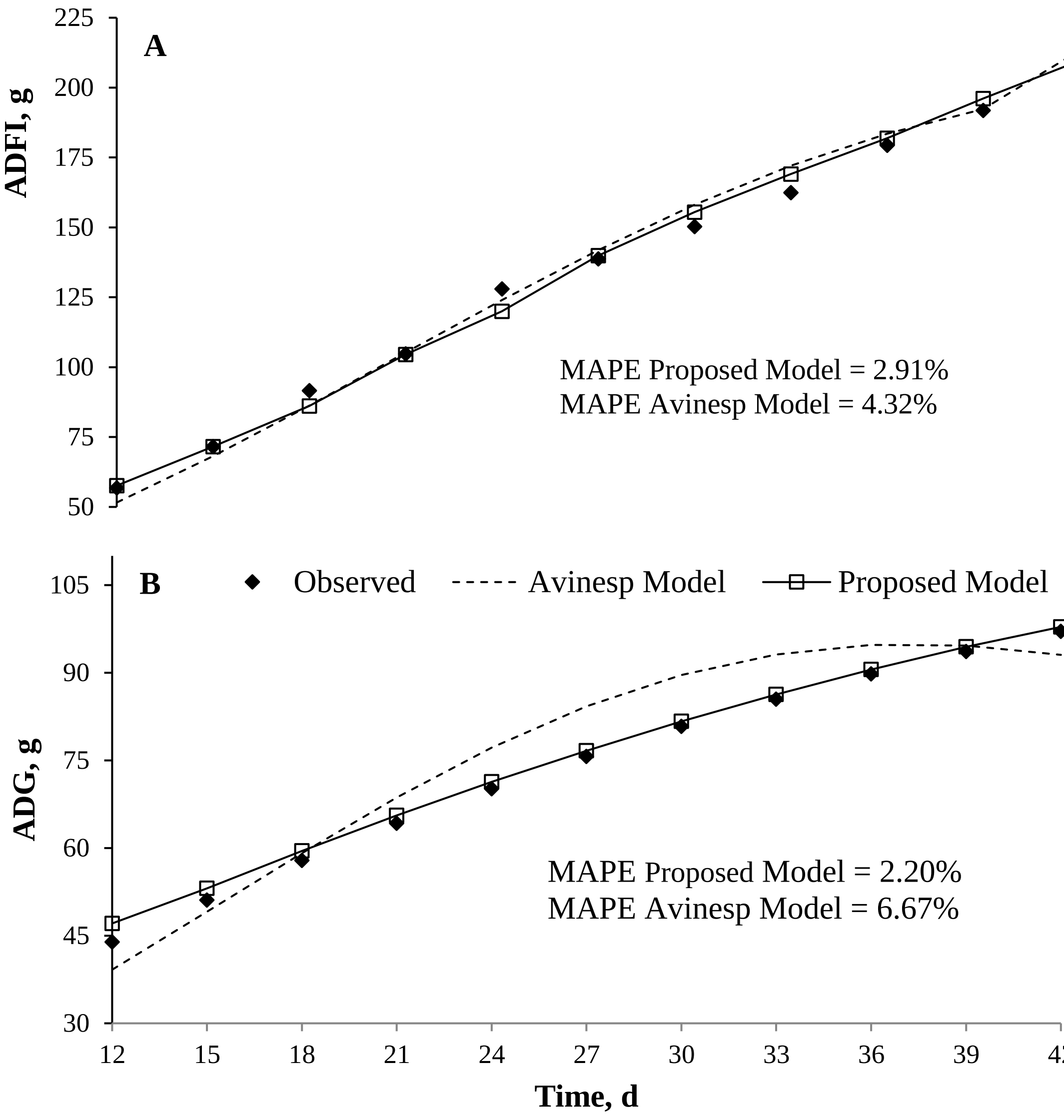

Figure 3. Average daily feed intake (A) and average daily gain (B) observed and estimated by the proposed and Avinesp models.

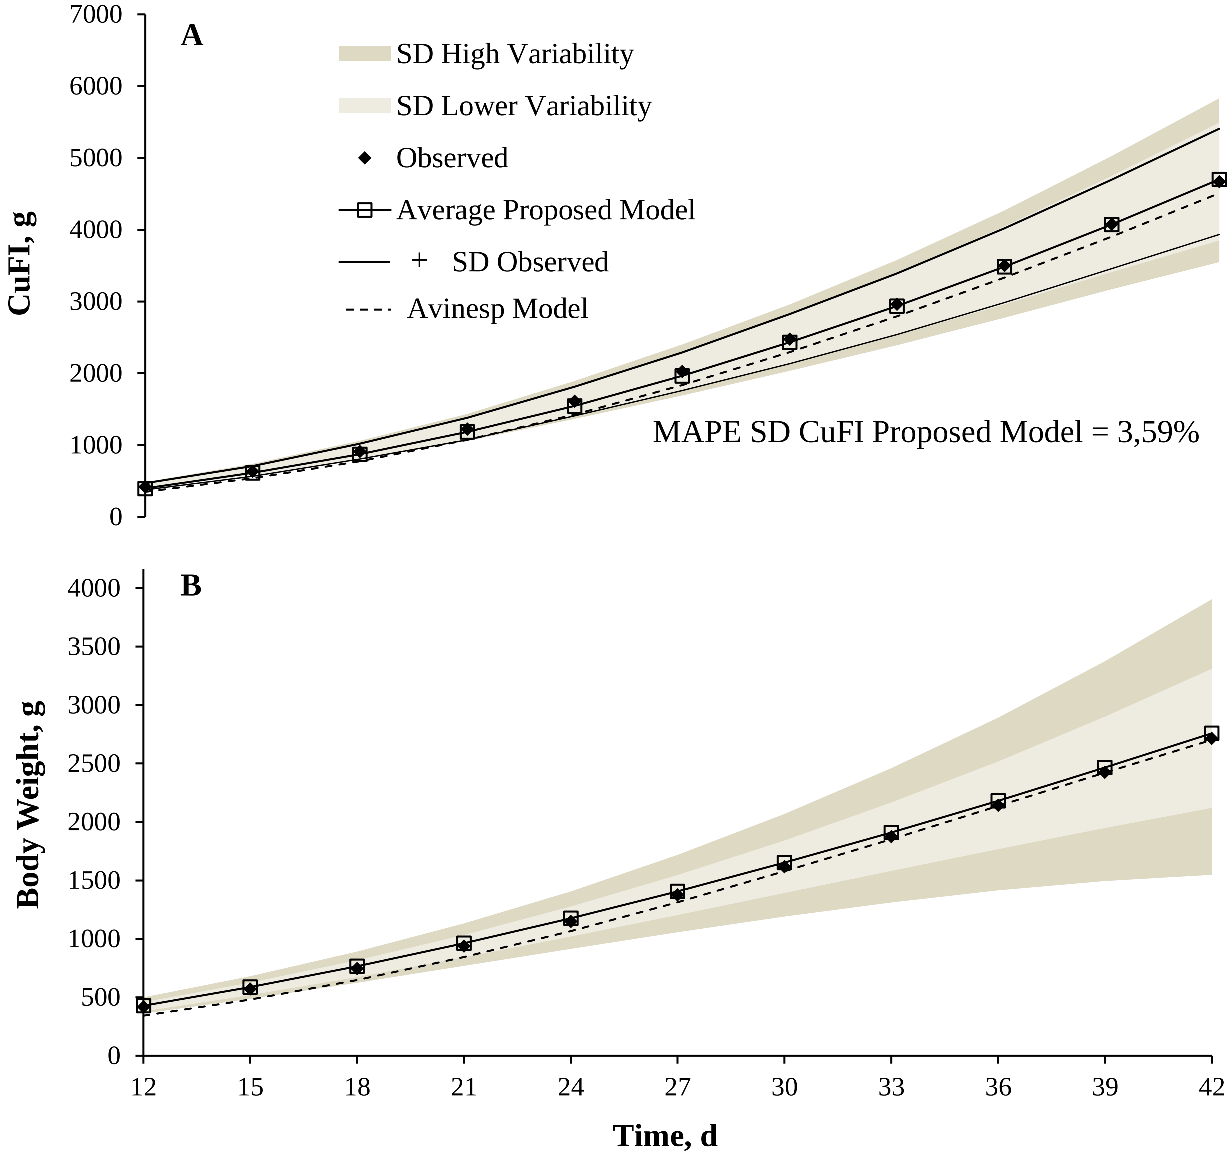

Figure 4. Cumulative feed intake (CUFI, A) and body weight (B) as well as their variabilities (High, represented by a commercial condition simulated; and Low, represented by an experimental condition observed) observed and estimated by proposed and Avinesp models**.**

The proposed model allows to estimate CuFI variability from the observed BW variability, differently of Avinesp, which only estimates DFI and DG for the average bird of a given population. The SD CuFI estimated by the equation [13] of the proposed model, followed a similar pattern with smaller error (MAPE = 3.59%) compared to observed values (Figure 4A). However, the proportional increase of the SD for CuFI observations at lower variability to higher variability was smaller than the observed for BW (41% vs. 100).

As expected, the CV BW for the average period was 6.88 and 13.77% at lower variability and higher variability, respectively. However, the CV BW increased as a function of the age with values of 10.96% at lower variability and 21.92% at higher variability on the last day of the simulation. For CuFI, an average CV of 6.76 at lower variability and 9.55% at higher variability was observed. Similar to BW, the variability of CuFI also increased as a function of age with CV values of 8.78 and 12.42% at the last day of the simulation at lower variability and higher variability, respectively.

Mechanistic Model Component

The proposed model, as well as the parameters values, allowed estimating coherent SIDLys requirements (Figures 5A and 5B). The absolute SIDLys requirement (mg/d) estimated by the model showed a linear increase over the simulated period, whereas the requirements estimated by the Avinesp Model increased in a quadratic manner (Figure 5A). The average SIDLys,% for the entire period estimated by the proposed model was similar to that obtained by Avinesp (SIDLys: 1.08 *vs.* 1.09% , Figure 5B). However, SIDLys,% estimated by the proposed model were higher in the initial and final period (in average +3%) and lower in the intermediate period (in average -4%) compared to the requirements obtained by Avinesp.

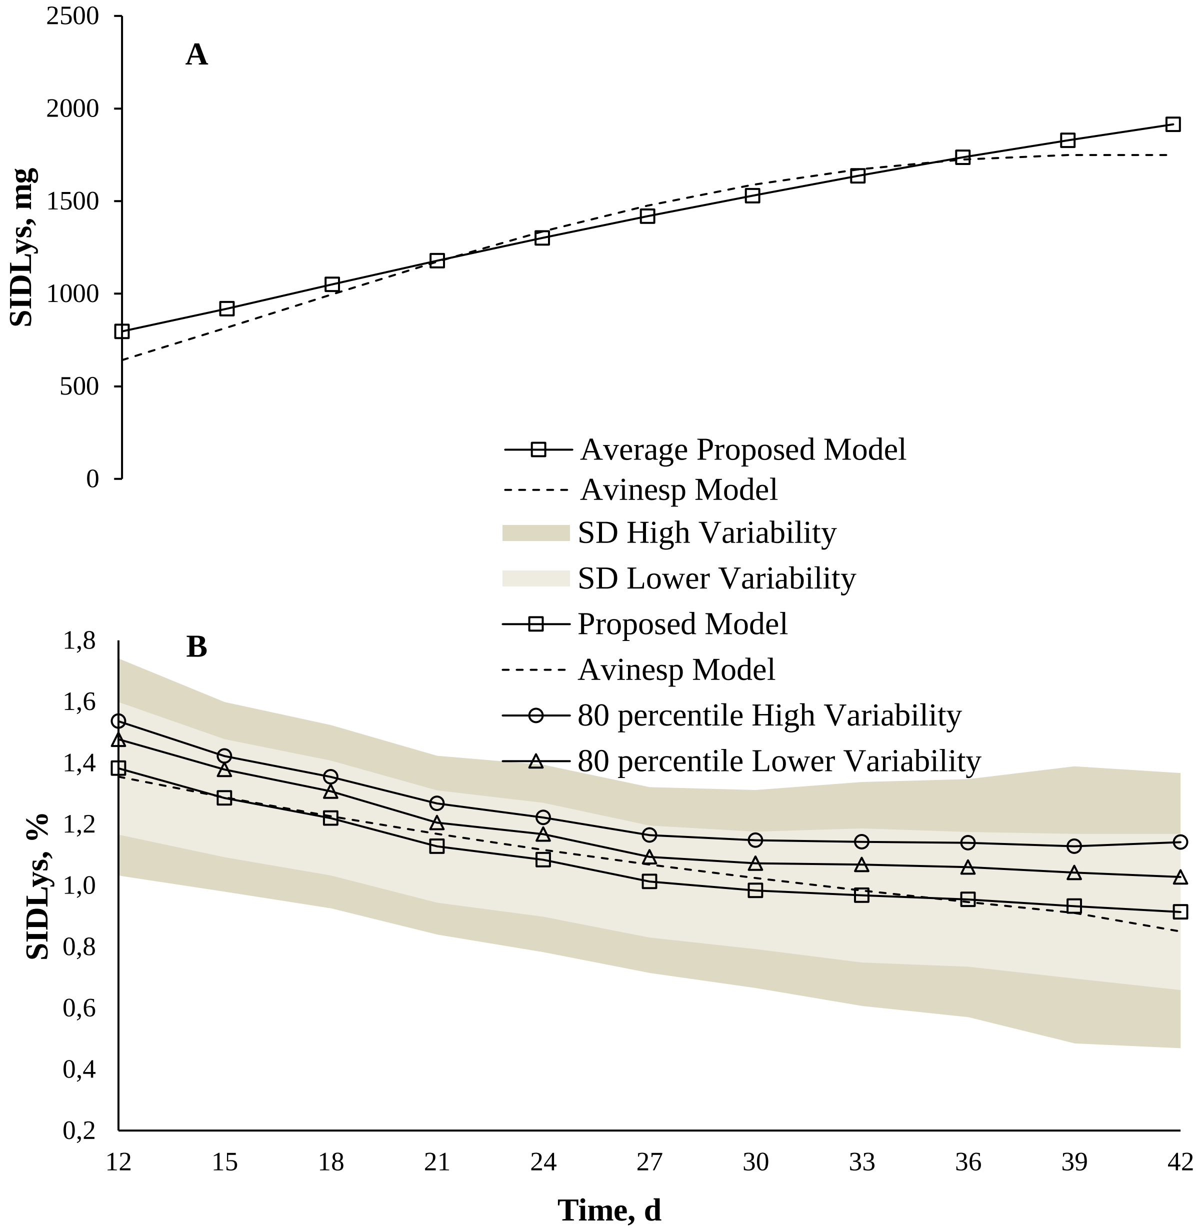

Figure 5. Standard ileal digestible lysine (SIDLys) in milligrams (A), and SIDLys diet concentration (B), as well as your variabilities (High, represented by a commercial condition simulated; and Low, represented by an experimental condition observed) estimated by the proposed and Avinesp Models.

Based on a recursive modeling of DFI and DG, relative variability of feed efficiency and using a factorial equation, the model allows to estimate daily SIDLys requirements taking into account the flock heterogeneity. It should be noted that the Avinesp is a deterministic model, which allows estimating only requirements for the average individual of the flock. In the proposed model, the average SIDLys,% estimated for the entire period were 1.08 ± 21% for Lower variability and 1.08 ± 35% for Higher variability. The range between SIDLys requirements of the least and the most demanding individual of the population (considering 2 SD) were 33 and 50% for the lower variability and higher variability, respectively. In addition, the variability of the requirement increased over the simulated period with values at the last day ranging from 0.66 to 1.17 of SIDLys, % for Lower variability and from 0.46 to 1.37 of SIDLys, % for Higher variability. The mean values estimated for the entire period for 80th percentile were 1.17 and 1.24 of SIDLys, % for Lower variability and Higher variability, respectively. These values were on average 8.72 and 15.18% higher than those estimated for average individual for Lower variability and Higher variability, respectively.

DISCUSSION

Empirical Model Component

The proposed model presented high accuracy when estimating average DFI and DG for day *t*+1 (MAPE = 2.91 and 2.20, respectively). High MAPE values, however, were observed in the Avinesp Model for DFI (4.32) and DG (6.67, Figures 3A, 3B). The parameters of the proposed model were adjusted for each three days using up-to-date information. On the other hand, the Avinesp model DFI and DG trajectories were previously calibrated by using observations taken from a group (flock data) in a rather inflexible function, which represents overall trends, ignoring short- and medium-term fluctuations. Moreover, the lower precision of Avinesp may also be related to the use of the Gompertz equation (Gompertz, 1825), which is normally used to represent growth potential in a non-limiting condition (Wang and Zuidhof, 2004). Estimates from this equation show a sigmoid behavior, assuming a point of inflection (where PD is maximal) and subsequently a decrease in the growth rate as a function of the age of the animals. However, the growth behavior (DG) observed in the population evaluated during the simulated period was linear (Figure 3B). Therefore, the estimates of the proposed model presented behavior similar to the data observed, unlike the Avinesp model. Additionally, other real-time models used recursive linear regression over Gompertz to represent growth, once the linearity of the model makes the parameter estimation straightforward compared to non-linear models such as Gompertz (Aerts et al., 2003a; Aerts et al., 2003b). Due to the advances in genetic improvement associated with the early productive life, as well as possible challenges in the field, it is plausible that, at present, the broilers can present a linear growth instead of sigmoid, during the growing period. In this scenario, it is important to highlight the importance of models with flexibility and dynamism to adapt to different response behaviors, such as the case of the model proposed in the present study.

Based on the DFI and DG estimates it was possible to determine the CuFI and BW trajectories. The similarity of the estimates to the observed data shows that the model presented an excellent accuracy to follow the trajectory of CuFI and BW in real time (Figure 4A, 4B). In addition to following the BW and CuFI trajectories of the average individual, the model was able to estimate the CuFI variability based on the observed SD BW. The use of a mathematical model that allows estimating the average and variability of the animal response in real time can be an excellent tool to monitor the responses of the broilers in real time. In addition to identifying a deviation of the average trajectory caused by some challenge (ingredient change, temperature, diseases, management change), it is also possible to estimate its impact on flock variability. Furthermore, the model allows estimating the DFI and BW and their respective variability for the next day, whose are necessary for the daily adjustment of diets in a precision nutrition system. Although it is not an easy task, considering the variation in responses is an increasingly prominent challenge in poultry farming, both in the research and production sectors.

A model similar to the one developed in this study was proposed for pigs (Hauschild et al., 2012). However, this model estimates individual requirements, since it was developed to consider the individual variability in pig's response (Parsons et al., 2007). In poultry farming, although it is experimentally possible, this is still an economically unfeasible practice due to operational difficulties and its high cost in measure individual response. In the proposed model, however, it was possible to estimate the variability of DFI without the need to measure this variable individually. However, when simulating a scenario of high variability, the SD CuFI did not increase in the same proportion as in a simulated condition for low variability (Figure 3). In fact, it is difficult at this point to assess whether this behavior is consistent or not. Within the literature review we did not identify studies that evaluated the variability of broilers DFI behavior in different conditions. Therefore, the variability in DFI behavior related to BW in different conditions needs to be further evaluated.

The empirical approach used in proposed model to estimate DFI, DG and CuFI variability does not allow to represent the biological mechanisms involved in the changes of these variables over time. However, it estimates with good accuracy the DFI and DG trajectory changes and their respective variability for a broiler flock. This can be considered a positive feature of the model, since it gives flexibility to the model to deal with the many conditions that may arise in the field.

Mechanistic Model Component

The factorial approach used in the mechanistic component allows estimating the daily requirement of lysine for a broiler population considering the dynamics of intake and growth and their respective variability (Figure 5). However, the parameters used in the factorial equation which represents the average individual are the same as those used in current growth models. Thus, more studies should be performed to consider the variability of these parameters when estimating the requirement for a broiler population, allowing dynamic parameters and stochastic approach to be applied in the model. In spite of this aspect, the model allowed to estimate coherent lysine requirements, thus achieving the proposal of this study, which was to structure and conceptualize a model that estimates the optimal AA level for a broiler flock using information collected in real time.

In current growth models to estimate the optimal AA level, it is necessary to integrate a mathematical function that describes the broiler PD potential. In this sense, an equation (Bertrand et al., 2013) that estimates PD based on the DG was integrated into the proposed model. The PD can also be estimated through automatic optimization of parameters (e.g. nutrient utilization efficiency) in a mechanistic model based in intake and diet composition collected in real time (Stacey et al., 2004). However, this approach was designed to operate with information collected at longer interval (4 days) and non-daily intervals. Due to the daily variability in consumption and the complexity of mechanistic models, preference was given to using a constant PD/DG relation in the proposed model to estimate PD. Though, considering the continuous genetic improvement of the lineages, more studies should be conducted to better represent the current PD/DG of the broilers and also the possible variation in this characteristic in different flocks. In view of these aspects, the proposed model will be reassessed in the future and, nevertheless, improved by both the reassessment of parameters and equations and the possibility of more precise measurements in integrated management systems.

The behavior of the Lys requirements estimated over time by the proposed model for the average individual was different from that estimated by Avinesp (Figure 5A). This distinct behavior was expected due to the characteristics of the current growth models which were previously discussed (linear vs. sigmoidal functions). Another important aspect is that current growth models (references) estimate nutrient requirements based on the assumption that the potential of these animals is similar to that of the reference population. Thus, current growth models assume that there will be no changes in the conditions of production and consequently in the intake and growth trajectories. Some models, although mechanistically represent the factors that affect intake and growth (temperature, sanitary challenges, etc.), are of low accuracy and are often too complex (calibration) to be applied in a commercial condition of production (MacNamara, 2006).

In addition to the requirement for the average individual, the proposed model also allows estimating nutrient requirements for different proportions (percentiles) of the population. In this context, in vivo (Brossard et al.,2014) and in silico (Brossard et al.,2009; Hauschild et al. 2010; Brossard et al., 2014). studies showed that feeding a population based on the individual that represents 80% (80^{th} percentile) of the requirement allows to optimize the performance of growing-finishing pigs. The SIDLys estimated by the propose model for the individual representing 80^{th} percentile was 8% (Lower variability) and 15% (Higher variability) higher than that estimated for the average individual (Figure 5B). At present, it was not possible to find studies that estimated amino acids requirements for different individuals in a bird flock to compare with the results of the present study. However, nutrient requirements estimated based on dose-response studies that compared the Linear Response Plateau (average individual) and Quadratic Linear Plateau (90-95% of population requirement) functions can be used for this purpose. In this context, Pesti et al. (2009) observed that the SID Lys level to optimize population response (Quadratic Linear Plateau) was on average 9% higher compared to the average individual (Linear Response Plateau). The similarity of this difference in lower variability scenario simulated in this study may be explained by the good management and environmental conditions normally observed under experimental conditions. In a commercial system, where broilers are constantly exposed to different challenges, greater variability in nutrient requirements (similar to the higher variability scenario) may be expected.

In this context, when feeding animals based on the requirement of the average individual, part (50%) of the animals will be provided with nutrients below their requirements, limiting part ofthe population to express its maximum potential (Brossard et al., 2009; Hauschild et al., 2010, Pomar et al., 2003). On the other hand, feeding a population based on the most demanding individuals (e.g., 90-95th percentile) may reflect lower nutritional efficiency, increased cost, and nutrient excretion. Some stochastic models, which allow to characterize a population of individuals considering the relation between the parameters of the model, have been proposed for birds (Johnston and Gous, 2007) and pigs (van Milgen et al., 2008; Brossard et al., 2009). Based on the integration of variability, these models allow, through stochastic simulations, to estimate the optimal nutrient level to optimize performance as well as economic response (marginal response) for a population. However, these approaches use information collected a priori and, therefore, do not allow taking into account the current variation between animals and over time observed in the actual flock. In the case of deterministic models (e.g. Avinesp - average individual), the estimation error may be even greater for populations with high heterogeneity (Pomar et al., 2003; Brossard et al., 2009).

Another limiting aspect within a practical context of broiler feeding refers to the provision of a single diet over a long period (phase feeding programs). In these programs it may be a complex activity estimate the optimal diet composition based on current growth models.

The nutrient requirements in a broiler population is influenced by several factors (sanitary, management, genetics, etc.), which can result in high variation among individuals and over time. The use of current growth models, therefore, is complex due to difficulties in both the calibration process (reference population) and in adequately considering the effect of variability among individuals in setting the optimal level to optimize population response (performance and economic). It is important to emphasize when evaluating different nutritional and feed scenarios these models have been considered effective tools to assist in decision-making. However, in a specific condition (e.g., nutrient levels for a specific flock), current growth model may present limitations that compromise accuracy in estimating nutritional requirements and optimize actual flock response.

Finally, the proposed model developed in this study has the potential to be integrated into feeders' system and provide to each broiler flock with daily tailored diets. However, in a condition of low sanitary status, where may be observed an abrupt reduction of intake and gain, it is not recommended the automatic estimation of nutrient requirements by the proposed model. Faced with this problem, there is the possibility of integrating an alarm system that can warn the farmer when a deviation from the normal intake and growth pattern is observed. In addition, there is also the possibility of integrating a submodel that, based on economic variables (e.g. diet costs), allows estimating an optimal economic AA level for the actual broiler flock. Therefore, the aspects addressed in this study represent important paradigm changes in the way of feeding and monitoring broilers in a commercial production context. In addition, it has been shown that daily adjustments in the diet composition - even based on a reference population - allow to reduce nutrient intake without affecting the performance of the broilers, compared to a 5 phases feeding program (Hauschild et al., 2015). Thus, feeding broilers with daily tailored diets through precision feed techniques can be an effective approach to optimize broiler flock response in real time. This is related to the fact that nutrient costs and excretion can be reduced, and feed efficiency can be improved, without reducing broiler performance. Thus, continuous estimation of the optimal nutrient level (optimizing performance or economic response) associated with feeding techniques that allow provide daily tailored diets are essential elements in order to advance in the development of precision feeding systems.

In conclusion, the proposed model can predict the average feed intake and body weight gain trajectory of each broiler flock in real-time with good accuracy. Based on recursive modeling of feed intake and growth, relative variability of feed efficiency and using a factorial equation, the model makes it possible to estimate daily AA requirements taking into account the flock heterogeneity. In an effort to develop sustainable precision farming systems for broilers, the proposed model can be integrated into an Integrated Management System with the objective to provide each broiler flock a daily tailored diet. Based on these techniques, precision feeding can be an effective approach to contribute to the reduction of the environmental load of broiler farms, while ensuring their economic viability.

REFERENCES

Aerts, J. M.; Lippens, M.; De Groote, G.; Buyse, J.; Decuypere, E.; Vranken, E.; Berckmans, D. 2003a. Recursive prediction of broiler growth response to feed intake by using a time-variant parameter estimation method. Poultry Science 821: 40-49.

Aerts, J. M.; Wathes, C. M.; Berckmans, D. 2003b. Dynamic Data-based Modelling of Heat Production and Growth of Broiler Chickens: Development of an Integrated Management System. Biosystems Engineering 843: 257-266.

Bertrand, M.; Haudchild, L.; Lescoat, P.; Sakomura, N. 2013. Modelisation de la croissance du poulet de chair : etablissement d'equations de reference pour estimer la composition corporelle. *Dixièmes Journées de la Recherche Avicole et Palmipèdes à Foie Gras.*

Brossard, L.; Dourmad, J. Y.; Rivest, J.; Van Milgen, J. 2009. Modelling the variation in performance of a population of growing pig as affected by lysine supply and feeding strategy. animal 38: 1114-1123.

Brossard, L.; Vautier, B.; van Milgen, J.; Salaun, Y.; Quiniou, N. 2014. Comparison of in vivo and in silico growth performance and variability in pigs when applying a feeding strategy designed by simulation to control the variability of slaughter weight. Animal Production Science 5412: 1939-1945

Castellini, C., Boggia, A., Cortina, C., Dal Bosco, A., Paolotti, L., Novelli, E., & Mugnai, C. 2012. A multicriteria approach for measuring the sustainability of different poultry production systems. *Journal of Cleaner Production 37:*192-201.

Dorigam, J. C. D. P., N. K. Sakomura, E. P. Da Silva, and J. B. K. Fernandes. 2014. Modelling the maximum potential of nitrogen deposition and requirements of lysine for broilers. Animal Production Science 54(12):1953-1959.

Edwards, H. M., & Baker, D. H. 1999. Maintenance lysine requirement and efficiency of using lysine for accretion of whole-body lysine and protein in young chicks. *Poultty Science 78*:1412-1417.

Frost, A. R. et al. 2003. Progress towards the development of an integrated management system for broiler chicken production. *Computers and Electronics in Agriculture* 39: 227-240.

Hauschild, L., Bueno, C. F. D., Remus, A., Gobi, J. D. P., Isola, R. D. G., & Sakomura, N. K. 2015. Multiphase feeding program for broilers can replace traditional system. *Scientia Agricola 72*(3): 210-214.

Hauschild, L., Lovatto, P. A., Pomar, J., & Pomar, C. 2012. Development of sustainable precision farming systems for swine: estimating real-time individual amino acid requirements in growing-finishing pigs. *Journal of Animal Science 90*(7): 2255-2263.

Hausschild, L., Sakomura, N. K. and Silva, E.P. 2014. Avinesp Model: Predicting Poultry Growth, Energy and Amino Acid Requirements. Pages 188-208 in Nutritional Modelling for Pigs and Poultry. N.K. Sakomura, R.M. Gous, I. Kyriazakis and L. Hauschild. 2014. 1st ed. Cabi Publishing - In Press, Wallingford, UK.

Kebreab, E., Schulin-Zeuthen, M., Lopez, S., Soler, J., Dias, R. S., De Lange, C. F. M., & France, J. 2007. Comparative evaluation of mathematical functions to describe growth and efficiency of phosphorus utilization in growing pigs. *Journal of animal science 85*(10): 2498-2507.

Kristensen A. R., Jørgensen E. and Toft N. 2010. "Advanced" topics from statistics. Herd management science II Advanced topics. University of Copenhagen, Faculty of life sciences, Department of large animal sciences, Copenhage.

Lee, D. Kyu, J. and Sangseok, L. Standard deviation and standard error of the mean. 2015. *Korean journal of anesthesiology 68*(3): 220-223.

Madsen, T. N., S. Andersen, and A. R. Kristensen. 2005. Modelling the drinking patterns of young pigs using a state space model. *Computers and Electronics in Agriculture* 48: 39-61.

Parsons, D. J., Green, D. M., Schofield, C. P., & Whittemore, C. T. (2007). Real-time control of pig growth through an integrated management system. *Biosystems engineering*, *96*(2), 257-266.

Pomar, C., L. Hauschild, G.-H. Zhang, J. Pomar, and P. A. Lovatto. 2009. Applying precision feeding techniques in growing-finishing pig operations. *Revista Brasileira de Zootecnia* 38: 226-237.

Pomar, C., van Milgen, J., Remus, A. 2016. Precision livestock feeding, principle and practice. In: Sustainable nutrition & feeding of pigs and poultry; Wageningen Academic publishers.

Rostagno, H. S., Albino, L. F. T.; Hannas, M. I.; Donzele, J. L; Sakomura, N. K.; Perazzo, F. G.; Saraiva, A. Abreu, M. L. T.; Rodrigues, P. B.; Oliveira, R. F.; Barreto, S. L. T.; Brito, C. O. 2011. Tabelas brasileiras para aves e suínos: composição de alimentos e exigências nutricionais. 3rd ed. Universidade Federal de Viçosa – Departamento de Zootecnia, UFV, Viçosa.

Rostagno, H. S., L. F. T. Albino, M. I. Hannas, J. L. Donzele, N. K. Sakomura, F. G. Perazzo, A. Saraiva, M. L. Teixeira, P. B. Rodrigues, R. F. Oliveira, S. L. T. Barreto, and C. O. Brito. 2017. Tabelas Brasileiras Para Aves e Suínos Composição de Alimentos e Exigências Nutricionais. 4 ed. UFV, Viçosa.

Roush, W. B. 2006. Advancements in empirical models for prediction and prescription. Page 97-106 in Mechanistic modeling in pig & poultry production. R.M Gous, T.R. Morris and C. Fisher. 1st ed. Cabi Publishing - In Press, Wallingford, UK.

Sakomura, N. K., F. A. Longo, E. O. Oviedo-Rondon, C. Boa-Viagem, and A. Ferraudo. 2005. Modeling energy utilization and growth parameter description for broiler chickens 1. Poultry Science 84(9):1363-1369.

Schinckel AP and de Lange CF. 1996. Characterization of growth parameters needed as inputs for pig growth models. *Journal of Animal Science 74*: 2021-2036.

Stilborn, H. L., Moran Jr, E. T., Gous, R. M., & Harrison, M. D. 2010. Influence of age on carcass (feather-free) amino acid content for two broiler strain-crosses and sexes. *Journal of Applied Poultry Research 19*(1): 13-23.

Wathes, C.; Kristensen, H. H.; Aerts, J.-M.; Berckmans, D. 2008. Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? Computers and Electronics in Agriculture 641: 2-10.

West, M., and J. Harrison. 1997. Bayesian Forecasting and Dynamic Models. Springer, New York, NY.

APÊNDICE

APÊNDICE 1 – Modelo (programação) desenvolvido no R no estudo de estimativa de exigências nutricionais exigências em tempo real para frangos de corte

COMPONENTE EMPIRICO DO MODELO

```
#################################################################################
# EMPIRICAL COMPONENT - Broiler real time mODEL
#################################################################################
## This script is undergoing to run a model with a optmize Beta for DAILY FEED INTAKE and
BWG

getwd()
setwd("C:/Users/hcw976/Dropbox/Orientacoes/Doutorado/Doutorado_Jaqueline/DOUTORADO/M
odelo_Final")
table <- read.table("DataObsFinal.txt", header = TRUE, sep="")
table
#################################################################################
# Defining variables
#################################################################################
Time<- table$Time
Intake<- table$Intake
Gain<- table$Gain

#################################################################################
# Matrix definition
#################################################################################
nt = 1
G = matrix(c(1, 0, 1, 1), 2)
F = matrix(c(1,0), 2)


#################################################################################
# Daily Feed intake model
# It is necssary to specify the mt and Ct values according to the data
#################################################################################

runDLMFI = function(y=y, beta=beta)     {

  theta = matrix(rep(0, length(y)*9), length(y))


  m = array(NA, c(length(y), 2))
  mt = c(14, 15)
  m[1,] = mt
  a = array(NA, c(length(y), 2))
  C = array(NA, c(length(y), 2, 2))
  Ct = matrix(c(10, 0, 0, 1), 2)
  C[1,,] = Ct
  R = array(NA, c(length(y), 2, 2))
```

```
St = 10
nt = 1

e = rep(NA, length(y))
Sde = rep(NA, length(y))
MaxFeed = array(NA, c(length(y)))
RelaFeed= array(NA, c(length(y)))

for (t in(1:length(y))) {
  at = G %*% mt
  a[t,] = at
  Rt = (G %*% Ct %*% t(G))/beta
  R[t,,] = Rt
  ft = t(F) %*% at
  Qt = t(F) %*% Rt %*% F + St
  Qt
  At = (Rt %*% F)/Qt[1,1]
  e[t] = (y[t] - ft)
  et = (y[t] - ft)
  Stet= et/sqrt(Qt[1,1])

  nt = nt + 1
  Sn = St + St/nt*(et*et/Qt[1,1] -1)
  mt = at + At %*% et
  m[t,] = mt
  Ct = (Sn[1,1]/St)*(Rt - ((At %*% t(At)) * Qt[1,1]))
  C[t,,] = Ct
  St = Sn[1,1]

  theta[t,1] = mt[1]
  theta[t,2] = mt[2]
  theta[t,3] = et
  theta[t,4] = Sn
  theta[t,5]= Stet
  theta[t, 8] = ft
  theta[t, 9] = Qt

}

# We ignore the variances
theta[length(y), 6] = theta[length(y), 1]
theta[length(y), 7] = theta[length(y), 2]
for (t in(1:(length(y)-1))) {
  Btt = C[length(y)-t,,] %*% t(G) %*% solve(R[length(y)-t+1,,])
  old = c(theta[length(y)-t+1,6], theta[length(y)-t+1,7])
  mtt = m[length(y)-t,] + Btt %*% (old-a[length(y)-t+1,])
  theta[length(y)-t,6] = mtt[1]
  theta[length(y)-t,7] = mtt[2]



}
```

```
  return(theta)
}

y <- table$Intake
vector <- seq(0.1,1,by=0.01)
res <- c()
i<-1

for (beta in vector) {
 theta <- runDLMFI(y, beta)
 res[i] <- sum(theta[,3]^2)
 i<- i+1;
}

min(res)
which(res==min(res))
betaOptFI = vector[which(res==min(res))]

############################################################################################
# Body weight gain model
# It is necssary to specify the mt and Ct values according to the data
############################################################################################

runDLMBW = function(y=y, beta=beta)  {

 theta = matrix(rep(0, length(y)*9), length(y))


 m = array(NA, c(length(y), 2))
 mt = c(16, 8)
 m[1,] = mt
 a = array(NA, c(length(y), 2))
 C = array(NA, c(length(y), 2, 2))
 Ct = matrix(c(1, 0, 0, 0.1), 2)
 C[1,,] = Ct
 R = array(NA, c(length(y), 2, 2))
 St = 1
 nt = 1

 e = rep(NA, length(y))
 Sde = rep(NA, length(y))

 for (t in(1:length(y))) {
  at = G %*% mt
  a[t,] = at
  Rt = (G %*% Ct %*% t(G))/beta
  R[t,,] = Rt
  ft = t(F) %*% at
  Qt = t(F) %*% Rt %*% F + St
  Qt
  At = (Rt %*% F)/Qt[1,1]
  e[t] = (y[t] - ft)
  et = (y[t] - ft)
```

```
    Stet= et/sqrt(Qt[1,1])

    nt = nt + 1
    Sn = St + St/nt*(et*et/Qt[1,1] -1)
    mt = at + At %*% et
    m[t,] = mt
    Ct = (Sn[1,1]/St)*(Rt - ((At %*% t(At)) * Qt[1,1]))
    C[t,,] = Ct
    St = Sn[1,1]

    theta[t,1] = mt[1]
    theta[t,2] = mt[2]
    theta[t,3] = et
    theta[t,4] = Sn
    theta[t,5]= Stet
    theta[t, 8] = ft
    theta[t, 9] = Qt

  }

  # We ignore the variances
  theta[length(y), 6] = theta[length(y), 1]
  theta[length(y), 7] = theta[length(y), 2]
  for (t in(1:(length(y)-1))) {
    Btt = C[length(y)-t,,] %*% t(G) %*% solve(R[length(y)-t+1,,])
    old = c(theta[length(y)-t+1,6], theta[length(y)-t+1,7])
    mtt = m[length(y)-t,] + Btt %*% (old-a[length(y)-t+1,])
    theta[length(y)-t,6] = mtt[1]
    theta[length(y)-t,7] = mtt[2]

  }

  return(theta)
}

y <- table$Gain
vector <- seq(0.1,1,by=0.01)
res <- c()
i<-1

for (beta in vector) {
  theta <- runDLMBW (y, beta)
  res[i] <- sum(theta[,3]^2)
  i<- i+1;
}

min(res)
which(res==min(res))
betaOptBW = vector[which(res==min(res))]

################################################################################
# Run models
################################################################################
```

```
betaBW=0.7
betaFI=0.6
y <- table$Intake
resFI<-runDLMFI(y, beta)

y <- table$Gain
resBW<-runDLMBW(y, beta)


#################################################################################
# Plots for DFI and BWI, RED line is the estimate values and BLUE the observed
#################################################################################
PLOT_b <- function (data,limit=0.4) {

  #Layout Plot
  m = matrix(1:3, 3, 1)
  layout(m, widths=c(1,1,1), heights=c(1,1,1))
  par(layout, mar=c(5, 4, 2, 5)+0.1,oma=c(1.5,1,2,0))

  #First plot
  # Calculation
  y <- data$Intake
  resFI<-runDLMFI(y, betaFI)
  x <- data$Time

  plot(x, y, type = "l", xlab = "Day", ylab="Feed intake, g", col = "blue", ylim=c(0, 300))
  lines(x, resFI[,8], col = "red", lwd = 2)
  #lines(x, resFI[,6], col = "black", lwd = 2)

  #Second plot
  # Calculation
  y <- data$Gain
  resBW<-runDLMBW(y, betaBW)
  x <- data$Time
  plot(x, y, type = "l", xlab = "Day", ylab="Body Weight Gain g", col = "blue",  ylim=c(0, 200))

  lines(x, resBW[,8], col = "red", lwd = 2)
  #lines(x, resBW[,6], col = "black", lwd = 2)



}

PLOT_b (data=table)



#################################################################################
# Data Frame for DFI and BWG observed and estimates, and BW and Cummulative Feed intake
estimates and standart
deviation#############################################################################
  #DFI
```

```
  y <- table$Intake
  x <- table$Time
  resFI<-runDLMFI(y, betaFI)
  shortFIRes = as.data.frame(resFI[, c(8)])
  shortFIRes$Time = x
  shortFIRes= shortFIRes[, c(2, 1)]
  colnames(shortFIRes) = c("Time", "IntakeP")

  #BWG
  y <- table$Gain
  x <- table$Time
  resBW<-runDLMBW(y, betaBW)
  shortBWRes = as.data.frame(resBW[, c(8)])
  shortBWRes$Time = x
  shortBWRes= shortBWRes[, c(2, 1)]
  colnames(shortBWRes) = c("Time", "GainP")


  #merge DFI and BWG estimates

  tableFinal <- merge(shortFIRes, shortBWRes, all = T)
  tableFinal<-merge(table, tableFinal, all=T)


  # Calculating BW and Cumulative Feed values
  install.packages("dplyr")
  library(dplyr)

  tableFinal<- tableFinal %>% mutate(BW1 = (GainP*3)+BWini)
  tableFinal<- tableFinal%>% mutate(BWp = cumsum(BW1))
  tableFinal<- tableFinal%>% mutate(CumFIp = cumsum(IntakeP*3))
  tableFinal<- tableFinal%>% mutate(VarBW = (SDBW^2))
  tableFinal<- tableFinal %>%select(Time, Intake, Gain, IntakeP, GainP, BWp, CumFIp, SDBW,
VarBW)
```

COMPONENTE MECANICISTA DO MODELO

```
# MODELLING NUTRIENT REQUIREMENT POPULATION CHICKENS IN REAL TIME

##################################################################################
# Getting the data set
getwd()
setwd("C:/Users/hcw976/Dropbox/Orientacoes/Doutorado/Doutorado_Jaqueline/DOUTORADO/M
odelo_Final_R")

day=tableFinal$Time
BW=tableFinal$BWp
BWG=tableFinal$GainP
FI=tableFinal$IntakeP  # Feed Intake
FIc=tableFinal$CumFIp   # Feed intake cumulative
VarBW= (tableFinal$VarBW)  # Variance BW

####################################################################################
#Defining Population size
Popsize=1000
###################################################################################
#Defining parameters Mecanistic model
LysC=0.070
LysEf= 0.72
Lysm=0.07
###################################################################################
# Data set of results
theta = matrix(rep(0, length(day)*11), length(day))
theta

###################################################################################
#Defining variables
# Empirical component
CovBWFI = array(NA, c(length(day))) # Relative variance of Efficiency
CV=array(NA, c(length(day))) # Coefficient variation
CVref= array(NA, c(length(day))) # Coefficient variation reference
FCova= array(NA, c(length(day))) # Fator adjust Cov
FVara=array(NA, c(length(day))) # Fator adjust Var

sdFIc = array(NA, c(length(day))) # standart desviation of feed intake cumulative
meanEf = array(NA, c(length(day))) # Mean feed Efficiency
sdEf= array(NA, c(length(day))) # sd of feed effiency
RelVar = array(NA, c(length(day))) # Relative variance of feed Efficiency
#Mecanicist Componente
PTBWG= array(NA, c(length(day))) # Protein deposition (g)
PD = array(NA, c(length(day))) # Protein deposition (g)
LysMant = array(NA, c(length(day))) # Lysine maintenance (mg)
Lysg=array(NA, c(length(day))) # Lysine requirement in gramas (mg)
LysDiet=array(NA, c(length(day))) # Lysine requirement diet (%)
sdLysDiet=array(NA, c(length(day))) # Sd Lysine requirement diet (%)
sdLysDietH=array(NA, c(length(day))) # +2 Sd Lysine requirement diet (%)
sdLysDietL=array(NA, c(length(day))) # -2 Sd Lysine requirement diet (%)
```

```
LysDiet_50=array(NA, c(length(day))) # Percentil 50% Lysine requirement diet simulation (%)
LysDiet_80=array(NA, c(length(day))) # Percentil 80% Lysine requirement diet simulation (%)


################################################################################
#Estimating Relative variance
for (t in(1:length(day))) {
  CovBWFIa= 0.00001*(BW[t]^2.86425)

  CovBWFI[t]=CovBWFIa


}

for (t in(1:length(day))) {

  CV=(((sqrt(VarBW[t]))/BW[t])*100)

  CVRef= -0.0000003*BW[t]^2 + 0.0026319*BW[t] + 3.4531069 # Coefficient reference
  FCova= CV/CVRef # Fator adjuste Cov
  FVar= 1/FCova # Fator adjuste Var


  CorrBWFI= 0.7939+0.00002*BW[t]
  sdFi= sqrt (((CovBWFI[t]*FCova)^2)/((CorrBWFI^2) * (VarBW[t]*FVar)))
  sdFIc[t]=sdFi

  theta[t,1] = sdFi[1]

}


for (t in(1:length(day))) {
  meanEfe= mean(rnorm(Popsize,BW[t],sqrt(VarBW[t]))/(rnorm(Popsize,FIc[t],sdFIc[t])))
  sdEfe= sd(rnorm(Popsize,BW[t],sqrt(VarBW[t]))/(rnorm(Popsize,FIc[t],sdFIc[t])))
  meanEf[t] = meanEfe
  sdEf[t]=sdEfe

  }

for (t in(1:length(day))) {

RelVare=  (sdEf[t])/(meanEf[t])
RelVar[t]= RelVare
RelVare

theta[t,2] = RelVare[1]
}

################################################################################
##
# Componente mecanicista
# Estimating mean Lys requirement
```

```
for (t in(1:length(day))) {

  PTBWG=(exp((1.06*log(BW[t]))-2.16))/BW[t] # From Bertram et al. 2013 (original value of
a=1.04)

  PDe=  BWG[t]* PTBWG


  PD[t]=PDe

  theta[t,3] = PDe[1]
}

for (t in(1:length(day))) {

  Lysme=  (Lysm * (BW[t]/1000)^0.75)*1000
  LysMant[t]=Lysme

  theta[t,4] = Lysme[1]
}

for (t in(1:length(day))) {

  Lysge=  (LysMant[t] + (((PD[t]*1000)*LysC)/LysEf))
  Lysg[t]=Lysge

  theta[t,5] = Lysge [1]
}

for (t in(1:length(day))) {

  LysDiete=  ((Lysg[t]/1000)/FI[t])*100
  LysDiet[t]=LysDiete

  theta[t,6] = LysDiete [1]
}

#Estimating Lysine requirement varibility
for (t in(1:length(day))) {

  sdLysDiete=  RelVar[t]*LysDiet[t]
  sdLysDiet[t]=sdLysDiete
  sdLysDietHe= LysDiet[t]+(sdLysDiete*2)
  sdLysDietLe= LysDiet[t]-(sdLysDiete*2)

  sdLysDietH[t]= sdLysDietHe
  sdLysDietL[t]= sdLysDietLe


  theta[t,7] =sdLysDiete [1]
  theta[t,8] =sdLysDietHe [1]
  theta[t,9] =sdLysDietLe [1]
}
```

```
for (t in(1:length(day))) {

  LysDietPop  <- rnorm(Popsize,LysDiet[t],sdLysDiet[t])
  LysDiet_50e <- as.numeric(quantile(LysDietPop, .50))
  LysDiet_80e <- as.numeric(quantile(LysDietPop, .82))

  LysDiet_50[t]=LysDiet_50e
  LysDiet_80[t]=LysDiet_80e


  theta[t,10] = LysDiet_50e [1]
  theta[t,11] = LysDiet_80e [1]

}


plot(day, theta[,6], type = "l",  ylim=c(0.2,2), xlab = "Day", ylab="Lys Requiment, %", col = "blue")
lines(day,theta[,10], col = "blue", lwd = 2)
lines(day,theta[,11], col = "green", lwd = 2)
lines(day,theta[,8], col = "red", lwd = 2)
lines(day,theta[,9], col = "red", lwd = 2)


#Data frame
x <- table$Time
x = x[4:length(x)]
Result_mec = as.data.frame(theta)
Result_mec$Time = x
Result_mec= Result_mec[, c(12, 1,2,3,4,5,6,7,10,11,8,9)]
colnames(Result_mec) = c("Time","SD_FI", "Rela_Var", "PD", "LysMant", "LysG", "LysDiet",
"SD_LysDiet", "LysDiet_50","LysDiet_80","+2SD_LysDiet","-2SD_LysDiet")
write.csv(Result_mec, file="Resultado_mecanicista.csv")
```